

ПРИКАСПИЙСКИЙ ЖУРНАЛ



УПРАВЛЕНИЕ И ВЫСОКИЕ
ТЕХНОЛОГИИ

2025
№3 (71)



ISSN 2074-1707

АСТРАХАНСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ В. Н. ТАТИЩЕВА

ПРИКАСПИЙСКИЙ ЖУРНАЛ: управление и высокие технологии

НАУЧНО-ТЕХНИЧЕСКИЙ ЖУРНАЛ

2025

№ 3 (71)

Журнал включен в перечень рецензируемых научных изданий, рекомендованных ВАК России для публикации основных научных результатов диссертаций на соискание ученой степени кандидата наук, на соискание ученой степени доктора наук по следующим научным специальностям.

Группа специальностей 1.2 «Компьютерные науки и информатика»:

1.2.2 – Математическое моделирование, численные методы и комплексы программ (технические науки).

Группа специальностей 2.2 «Электроника, фотоника, приборостроение и связь»:

2.2.4 – Приборы и методы измерения (по видам измерений) (технические науки);

2.2.11 – Информационно-измерительные и управляющие системы (технические науки);

2.2.12 – Приборы, системы и изделия медицинского назначения (технические науки).

Группа специальностей 2.3 «Информационные технологии и телекоммуникации»:

2.3.1 – Системный анализ, управление и обработка информации (технические науки);

2.3.4 – Управление в организационных системах (технические науки);

2.3.5 – Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей (технические науки);

2.3.6 – Методы и системы защиты информации, информационная безопасность (технические науки).

Журнал входит в базу данных Ulrich's Periodicals Directory.

Астрахань

Астраханский государственный университет имени В. Н. Татищева

2025

Рекомендовано к печати редакционно-издательским советом
Астраханского государственного университета имени В. Н. Татищева

ПРИКАСПИЙСКИЙ ЖУРНАЛ:
управление и высокие технологии
НАУЧНО-ТЕХНИЧЕСКИЙ ЖУРНАЛ

2025
№ 3 (71)

Редакционная коллегия

А.М. Лихтер, доктор технических наук, профессор, профессор-консультант кафедры физики, профессор кафедры информационных технологий, ведущий научный сотрудник Научно-образовательного центра «Рациональное использование природных ресурсов» Астраханского государственного университета им. В. Н. Татищева (главный редактор)

И.В. Аникин, доктор технических наук, профессор, заведующий кафедрой «Системы информационной безопасности» Казанского национального исследовательского технического университета им. А.Н. Туполева – КАИ

А.А. Большаков, доктор технических наук, профессор, профессор кафедры «Системы автоматизированного проектирования и управления» Санкт-Петербургского государственного технологического института (технического университета)

Л.А. Демидова, доктор технических наук, профессор, профессор кафедры «Вычислительной и прикладной математики» Рязанского государственного радиотехнического университета

А.С. Катасёв, доктор технических наук, профессор, профессор кафедры систем информационной безопасности Казанского национального исследовательского технического университета им. А.Н. Туполева – КАИ

И.Ю. Квятковская, доктор технических наук, профессор, директор Института информационных технологий и коммуникаций Астраханского государственного технического университета

А.Г. Кравец, доктор технических наук, профессор, профессор кафедры «Системы автоматизированного проектирования и поискового конструирования» Волгоградского государственного технического университета

В.Ю. Кузнецова, кандидат технических наук, старший преподаватель кафедры информационной безопасности Астраханского государственного университета им. В. Н. Татищева

Ю.В. Литовка, доктор технических наук, профессор, профессор кафедры «Системы автоматизированной поддержки принятия решений» Тамбовского государственного технического университета

А.А. Лобатый, доктор технических наук, профессор, заведующий кафедрой «Информационные системы и технологии» Белорусского национального технического университета (Республика Беларусь, г. Минск)

Е.В. Никульчев, доктор технических наук, профессор, профессор кафедры «Управление и моделирование систем» Московского технологического университета (МИРЭА)

В.О. Осипя, доктор физико-математических наук, доцент, профессор кафедры «Информационные технологии» Кубанского государственного университета (г. Краснодар)

И.Ю. Петрова, доктор технических наук, профессор, первый проректор Астраханского государственного архитектурно-строительного университета, заведующая кафедрой САПР Астраханского государственного архитектурно-строительного университета

А.В. Рыбаков, кандидат физико-математических наук; доцент кафедры технологии материалов и промышленной инженерии Астраханского государственного университета им. В.Н. Татищева

А.В. Скрипаль, доктор физико-математических наук, профессор, заведующий кафедрой «Медицинская физика» Саратовского национального исследовательского государственного университета им. Н.Г. Чернышевского

И.Б. Старченко, доктор технических наук, профессор, ООО «Параметрика», научный руководитель (г. Таганрог Ростовской области)

Т.Л. Тен, доктор физико-математических наук, профессор кафедры «Информационно-вычислительные системы» Карагандинского экономического университета (Республика Казанстан, г. Караганда)

Е.Н. Тищенко, доктор экономических наук, профессор, заведующий кафедрой «Информационные технологии и защита информации» Ростовского государственного экономического университета (РИНХ) – г. Ростов-на-Дону

С.А. Филит, доктор технических наук, профессор, профессор кафедры «Биомедицинская инженерия» Юго-Западного государственного университета (г. Курск)

Л.Р. Филонова, доктор технических наук, профессор, декан факультета Вычислительной техники, заведующая кафедрой «Информационное обеспечение управления и производства» Пензенского государственного университета

В.А. Цимбал, заслуженный деятель науки РФ, доктор технических наук, профессор, профессор кафедры «Автоматизированные системы управления» (Филиал Военной академии РВСН им. Петра Великого МО в г. Серпухов Московской области)

Н.К. Юрков, заслуженный деятель науки РФ, доктор технических наук, профессор, заведующий кафедрой «Конструирование и производство радиоаппаратуры» Пензенского государственного университета

N.A. Kolesova, PhD, Check Point Software Technologies LTD, Tel-Aviv, Israel

Serg Miranda, PhD (Toulouse University, France), – Master thesis at UCLA (University of California, Los Angeles with an INRIA Scholarship), Professor of Computer Science, University of Nice – Sophia Antipolis (Nice, France), Director of the CS dept. and MBDS innovation lab (www.mbds-fr.org)

Журнал выходит 4 раза в год
Все материалы, поступающие в редколлегию журнала,
проходят независимое рецензирование

© Астраханский государственный университет,
имени В. Н. Татищева, 2025
© Гайфитдинова С. Ю., дизайн обложки, 2025

ASTRAKHAN TATISHCHEV STATE UNIVERSITY

**PRIKASPIYSKIY ZHURNAL:
Upravlenie i Vysokie Tekhnologii**

**CASPIAN JOURNAL:
Control and High Technologies**

A SCIENTIFIC AND TECHNICAL JOURNAL

**2025
No. 3 (71)**

The journal is included in the list of the reviewed scientific journals recommended by VAK of Russia for the publication of the main scientific results of theses for the candidate of science degree, for the doctor of science degree on the following scientific specialties.

Group of specialties 1.2 “Computer science and informatics”:

1.2.2 – Mathematical modelling, numerical methods and complexes of programmes (technical sciences).

Group of specialties 2.2 “Electronics, photonics, instrument engineering and communication”:

2.2.4 – Instruments and methods of measurement (by type of measurement) (technical sciences);

2.2.11 – Information-measuring and control systems (technical sciences);

2.2.12 – Medical devices, systems and products (technical sciences).

Group of specialties 2.3 “Information technologies and telecommunications”:

2.3.1 – System analysis, information control and processing (technical sciences);

2.3.4 – Management in organizational systems (technical sciences);

2.3.5 – Mathematical software and software for computing systems, complexes and computer networks (technical sciences);

2.3.6 – Information security methods and systems, information security (technical sciences).

The journal is included into the database Ulrich’s Periodicals Directory.

Astrakhan
Astrakhan Tatishchev State University
2025

Recommended by the Editorial and Publishing Board
of Astrakhan Tatishchev State University

**CASPIAN JOURNAL:
Control and High Technologies**

A SCIENTIFIC AND TECHNICAL JOURNAL

2025

No. 3 (71)

Editorial Board

A.M. Likhter, Doct. Sci. (Engineering), Professor, Consulting Professor of the Department of Physics, Professor of the Department of Information Technology, Leading Researcher of the Scientific and Educational Center "Rational Use of Natural Resources", Astrakhan Tatishchev State University (**Editor-in-Chief**)

I.V. Anikin, Doct. Sci. (Engineering), Professor, Head of Information Security System Department, Kazan National Research Technical University named after A.N. Tupolev – KAI

A.A. Bolshakov, Doct. Sci. (Engineering), Professor of «Systems of Automated Design Engineering and Control» department, St. Petersburg State Technological Institute (Technical University)

L.A. Demidova, Doct. Sci. (Engineering), Professor, Professor of the Computational and Applied Mathematics Department, Ryazan State Radio Engineering University

A.S. Katasev, Doct. Sci. (Engineering), Associate Professor, Professor of the Department of Information Security Systems, Kazan National Research Technical University. A.N. Tupolev – KAI

I.Yu. Kvyatkovskaya, Doct. Sci. (Engineering), Professor, Head of "Information Technologies and Communications" Institute of the Astrakhan State Technical University

A.G. Kravets, Doct. Sci. (Engineering), Professor, Professor of the Automated Design Engineering Systems and Search Constructing Department, Volgograd State Technical University

V.Yu. Kuznetsova, Cand. Sci. (Engineering), Senior Lecturer of Information Security Department, Astrakhan Tatishchev State University

Yu.V. Litovka, Doct. Sci. (Engineering), Professor, Professor of the Department of Automated Support System for Decision-Making, Tambov State Technical University

A.A. Lobaty, Doct. Sci. (Engineering), Professor, Head of Information Systems and Technologies Department, Belarusian National Technical University (Belarus, Minsk)

E.V. Nikulchev, Doct. Sci. (Engineering), Professor, Professor of the System Management and Modeling Department, Moscow Technological University

V.O. Osipyan, Doct. Sci. (Physics and Mathematics), Professor of the Kuban State University (Krasnodar)

I.Yu. Petrova, Doct. Sci. (Engineering), Professor, First Vice-Rector of the Astrakhan State Architectural and Construction University, Head of the CAD department of Astrakhan State Architectural and Construction University

A.V. Rybakov, Cand. Sci. (Physics and Mathematics), Associate Professor, Department of Materials Technology and Industrial Engineering Astrakhan Tatishchev State University

A.V. Skripal, Doct. Sci. (Physics and Mathematics), Professor, Head of Medical Physics Department of the Saratov national research State University named after N.G. Chernyshevsky

I.B. Starchenko, Doct. Sci. (Engineering), Professor, OOO «Parametrica» (Taganrog, Rostov Oblast), Research Supervisor

T.L. Ten, Doct. Sci. (Engineering), Professor, Karaganda Economic University (Republic of Kazakhstan, Karaganda)

E.N. Tishchenko, Doct. Sci. (Economics), Professor, Head of the Information Technologies & Information Security Department, Rostov State University of Economics, Rostov-on-Don

S.A. Filist, Doct. Sci. (Engineering), Professor, Professor of Biomedical Engineering Department, Southwest State University (Kursk)

L.R. Fionova, Doct. Sci. (Engineering), Professor, Dean of the Computer Technology Faculty, Head of the Department «Information Support of Management and Production, Penza State University

V.A. Tsimbal, Doct. Sci. (Engineering), Honored Worker of Science of the Russian Federation, Professor, Professor of the Automated Control Systems Department (Branch of the Military Academy of the Russian Strategic Missile Forces named after Peter the Great of the Moscow Oblast, Serpukhov, Moscow Oblast)

N.K. Yurkov, Honored worker of science of the Russian Federation, Doct. Sci. (Engineering), Professor, Head of the department «Designing and production of the radio equipment», Penza State University

N.A. Kolesova, PhD, Check Point Software Technologies LTD, Tel-Aviv, Israel

Serg Miranda, PhD (Toulouse University, France), – Master thesis at UCLA (University of California, Los Angeles with an INRIA Scholarship), Professor of Computer Science dept., University of Nice – Sophia Antipolis (Nice, France), Director of the CS department and MBDS innovation lab (www.mbds-fr.org)

The journal is published four times a year
All materials that come to the Editorial Board of the journal
are subject to independent peer-review

© Astrakhan Tatishchev State University, 2025
© S. Yu. Gayfitdinova, cover design, 2025

СОДЕРЖАНИЕ

ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

МАТЕМАТИЧЕСКОЕ И ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ ВЫЧИСЛИТЕЛЬНЫХ МАШИН, КОМПЛЕКСОВ И КОМПЬЮТЕРНЫХ СЕТЕЙ

Ю. В. Гольчевский, Е. Ю. Турышев

Анализ использования сервис-ориентированных технологий
при разработке программного обеспечения 9–16

**М. А. Лапина, Ю. С. Браун, В. Г. Лапин,
Н. А. Шиянова, К. А. Гедиев**

Исследование методов машинного обучения
для обнаружения и предотвращения кибератак 17–27

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

А. В. Зубков, Г. А. Снигур, Е. М. Великанов, Д. А. Сальников

Сравнительный анализ методов компьютерного зрения, применяемых
для автоматического подсчета колониеобразующих единиц 28–37

Р. Ю. Демина, М. М. Ашимов, Д. А. Лепехин, В. Н. Есауленко

Формирование обучающего множества на основе данных
должников, хранимых коллекторским агентством 38–45

В. А. Частикова, С. А. Жерлицын, А. А. Титова

Методы идентификации личности по лицу в системах контроля
доступа: анализ и программная реализация выбранного подхода 46–59

В. А. Михайлик, Р. Ю. Демина, А. М. Меркулова, М. Ф. Руденко

Сравнительный анализ алгоритмов машинного обучения
для прогнозирования явки правонарушителей в суд 60–67

П. А. Шаронов, А. А. Львов

Использование случайных нечетких переменных для онлайн-оценки
неопределенности цифровых измерительных приборов 68–79

МЕТОДЫ И СИСТЕМЫ ЗАЩИТЫ ИНФОРМАЦИИ, ИНФОРМАЦИОННАЯ БЕЗОПАСНОСТЬ

В. А. Частикова, К. В. Козачек, Е. А. Чикиндина, П. В. Бушуева

Применение нейросетевых методов для обнаружения
и предотвращения фишинговых атак, направленных
на кражу персональных данных 80–87

М. Ю. Журавлев, А. В. Хайтуд, И. М. Ажмухамедов

Моделирование процесса передачи данных по протоколу TCP
в криптографически защищенных каналах с высокой задержкой
и ограниченной пропускной способностью 88–96

Ю. А. Андрусенко, В. Г. Лапин, И. В. Головин, А. А. Синицын

Аналитический обзор требований к системам разработки
безопасного программного обеспечения 97–104

М. А. Лапина, О. В. Криволапова, М. Р. Хамидов, З. В. Бесаева

Алгоритмы вычисления функций от одной переменной
для обработки зашифрованных чисел в распределенных средах 105–114

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ, ЧИСЛЕННЫЕ МЕТОДЫ И КОМПЛЕКСЫ ПРОГРАММ

О. Ю. Кожухарь, А. С. Скичко

Многовариантность решения оптимизационной задачи
поиска параметров математической модели
процесса биоразложения парацетамола 115–122

Ю. Ю. Калинина, К. Е. Лебедева, Ю. А. Смирнова

Создание цифрового ассистента
с использованием технологии Telegram-бота 123–130

Е. В. Поляков, С. Ю. Дорошин, Н. А. Филатова,

В. В. Дмитриева, И. А. Климанов

Программная система анализа результатов модели
глубокого обучения на примере изображений
ядросодержащих клеток из препаратов костного мозга 131–137

ПРИБОРОСТРОЕНИЕ, МЕТРОЛОГИЯ И ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ ПРИБОРЫ И СИСТЕМЫ

ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ И УПРАВЛЯЮЩИЕ СИСТЕМ

А. С. Звягин

Использование байесовского подхода к обработке данных
и принятию решений в информационно-измерительных системах
для повышения точности в условиях
неопределенности и неполноты информации 138–148

О. М. Лепешкин, О. А. Остроумов, М. М. Бычковский, С. П. Тесля

Устройство автоматизированного управления процессом
проектирования и построения сложной технической системы 149–157

Б. А. Серкин, А. В. Небылов

Моделирование и анализ влияния ветровых возмущающих
воздействий на полет малого беспилотного воздушного судна 158–168

ПРАВИЛА ДЛЯ АВТОРОВ 169

CONTENTS

INFORMATICS, COMPUTER TECHNIQUE AND CONTROL

MATHEMATICAL SOFTWARE AND SOFTWARE FOR COMPUTING MACHINES, COMPLEXES AND COMPUTER NETWORKS

Yu. V. Golchevskiy, E. Yu. Turyshev

The use of service-oriented technologies analysis in software development 9–16

M. A. Lapina, Yu. S. Brown, V. G. Lapin, N. A. Shiyanova, K. A. Gediev

Using interactive visualization tools for business process modeling 17–27

SYSTEM ANALYSIS, CONTROL AND INFORMATION PROCESSING

A. V. Zubkov, G. L. Snigur, E. M. Velikanov, D. A. Salnikov

Comparative analysis of computer vision methods used for automatic counting of colony-forming units 28–37

R. Y. Demina, M. M. Ashimov, D. A. Lepekhin, V. N. Esaulenko

Formation of a training set based on debtors' data stored by a collection agency 38–45

V. A. Chastikova, S. A. Zherlitsyn, A. A. Titova

Face recognition methods in access control systems: analysis and software implementation of the selected approach 46–59

V. A. Mikhailik, R. Yu. Demina, A. M. Merkulova, M. F. Rudenko

Comparative analysis of predictive models for offenders' court appearance based on machine learning methods 60–67

P. A. Sharonov, A. A. Lvov

Using random fuzzy variables for online uncertainty assessment of digital measuring instruments 68–79

METHODS AND SYSTEMS OF INFORMATION PROTECTION, INFORMATION SECURITY

V. A. Chastikova, K. V. Kozachek, E. A. Chikindina, P. V. Bushueva

Application of neural network methods to detect and prevent phishing attacks aimed at stealing personal data 80–87

M. Yu. Zhuravlev, A. V. Khaytul, I. M. Azhmukhamedov

Simulation of the TCP data transmission process in cryptographically secure channels with high latency and limited bandwidth 88–96

Yu. A. Andrusenko, V. G. Lapin, I. V. Golovin, A. A. Sinitsyn

Analytical review of requirements to secure software development systems 97–104

M. A. Lapina, O. V. Krivolapova, M. R. Hamidov, Z. V. Besaeva

Algorithms for calculating functions with a single variable for processing encrypted numbers in distributed environments 105–114

**MATHEMATICAL MODELLING, NUMERICAL METHODS
AND PROGRAM SYSTEMS**

O. Yu. Kozhukhar, A. S. Skichko

Multivariability solution of optimization problem
of searching parameters of mathematical model
of paracetamol biodegradation process 115–122

Yu. Yu. Kalinina, K. E. Lebedeva, Yu. A. Smirnova

Creation of a digital assistant using telegram bot technology 123–130

**E. V. Polyakov, S. Yu. Doroshin, N. A. Filatova,
V. V. Dmitrieva, I. A. Klimanov**

A software system for analyzing the results of a deep learning model
using images of nucleated cells from bone marrow preparations 131–137

**INSTRUMENT ENGINEERING, MEASUREMENT SCIENCE,
INFORMATION AND MEASURING DEVICES AND SYSTEMS**

INFORMATION, MEASURING AND CONTROL SYSTEMS

L. S. Zvyagin

Using a bayesian approach to data processing and decision-making
in information and measurement systems to improve accuracy
in conditions of uncertainty and incompleteness of information 138–148

O. M. Lepeshkin, O. A. Ostroumov, M. M. Bychkovskiy, S. P. Teslya

device for automated control of the process of designing
and constructing a complex technical system 149–157

B. A. Serkin, A. V. Nebylov

Modeling and analysis of the effect of wind disturbances
on the flight of a small UAV 158–169

RULES FOR THE AUTHORS 169

ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

МАТЕМАТИЧЕСКОЕ И ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ ВЫЧИСЛИТЕЛЬНЫХ СИСТЕМ, КОМПЛЕКСОВ И КОМПЬЮТЕРНЫХ СЕТЕЙ

УДК 004.4

АНАЛИЗ ИСПОЛЬЗОВАНИЯ СЕРВИС-ОРИЕНТИРОВАННЫХ ТЕХНОЛОГИЙ ПРИ РАЗРАБОТКЕ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ

Гольчевский Юрий Валентинович, Сыктывкарский государственный университет имени Питирима Сорокина, 167001, Российская Федерация, г. Сыктывкар, Октябрьский пр., 55, кандидат физико-математических наук, доцент, заведующий кафедрой прикладной информатики Института точных наук и информационных технологий, ORCID: 0000-0003-2047-9138, e-mail: yurygol@mail.ru

Турьшев Егор Юрьевич, ООО «Хэшлаб», 123112, Российская Федерация, г. Москва, Пресненская наб., 8, стр. 1, 603м, техник-программист, ORCID: 0009-0005-3304-037X, e-mail: egor.turyshev@mail.ru

В последнее время требования к информационным системам со стороны бизнес-среды значительно расширились, что вынуждает разработчиков искать новые программные архитектуры, позволяющие улучшить качество управления. Это обусловило то, что сервис-ориентированная парадигма становится более популярной благодаря возможности предоставления механизмов безопасного и эффективного взаимодействия сервисов друг с другом. Цель данной работы – представить современные практики использования сервис-ориентированных технологий в разработке программного обеспечения и дать некоторую оценку целесообразности применимости сервисного подхода, для чего требуется изучить причины появления подобных архитектурных решений, выполнить их анализ в контексте современного применения и изучить влияние внедрения распределенных вычислений на выполнение бизнес-задач. В работе проведен эксперимент с целью исследовать практическое влияние распределенных вычислений на производительность в рамках конкретной задачи. Описанный подход позволяет изучить возможность распределения нагрузки между различными узлами системы. В работе отмечена важность соблюдения баланса между размерами сервисов и их эффективностью, а также то, что каждый программный проект требует индивидуального подхода, основанного на анализе его специфики, объема задач и требований к производительности.

Ключевые слова: сервис-ориентированная архитектура, сервисы, высоконагруженные системы, масштабируемость

THE USE OF SERVICE-ORIENTED TECHNOLOGIES ANALYSIS IN SOFTWARE DEVELOPMENT

Golchevskiy Yuriy V., Pitirim Sorokin Syktyvkar State University, 55 Oktyabrsiy Ave., Syktyvkar, 167001, Russian Federation,

Cand. Sci. (Physics and Mathematics), Associate Professor, Head of the Applied Informatics Department, Institute of Exact Sciences and Information Technologies, ORCID: 0000-0003-2047-9138, e-mail: yurygol@mail.ru

Turyshev Egor Yu., Hashlab LLC, 603m, bldg. 1, 8 Presnenskaya Embankment, Moscow, 123112, Russian Federation, technician-programmer, ORCID: 0009-0005-3304-037X, e-mail: egor.turyshev@mail.ru

Recently, the requirements for information systems from the business environment have expanded significantly. This reality forces developers to look for and use new software structures and architectures to improve the quality of management. This has led to the fact that the service-oriented paradigm is becoming increasingly popular due to the ability to provide secure and efficient services interaction mechanisms. The purpose of the paper is to present modern practices of using service-oriented technologies in software development and to give some assessment of the service approach expediency, which requires studying the reasons for the emergence of architectural solutions in the service-oriented paradigm, analyzing them in the context of modern applications and studying the impact of the introduction of distributed computing on the business tasks performance. An experiment was conducted to investigate the practical impact of distributed computing on performance in a specific task. The described approach allows to explore the possibility of load distribution between different nodes of the system. The importance of maintaining a balance between the size of services and their effectiveness was noted, as well as the fact that each software project requires an individual approach based on an analysis of its specifics, scope of tasks and performance requirements.

Keywords: service-oriented architecture, services, high-load systems, scalability

ВВЕДЕНИЕ

Перманентный рост уровня автоматизации современного бизнеса требует все более сложных программных решений, способных поддерживать традиционные и новые бизнес-процессы. В условиях растущих требований к гибкости и масштабируемости ИТ-инфраструктуры традиционные подходы к разработке программного обеспечения, хорошо работавшие в XX в., уже не могли в полной мере удовлетворять новым потребностям бизнеса. Это стало особенно заметно на фоне увеличения объемов накапливаемых данных и необходимости их оперативной обработки. Потенциальным решением этих проблем стала парадигма сервис-ориентированных технологий и их использование при разработке программных решений.

Согласно данным ресурса [1], рынок промышленной автоматизации демонстрирует уверенный рост, увеличиваясь примерно на 9 % в год, что подчеркивает значительный спрос на технологии автоматизации и интеграции бизнес-процессов. В то же время рынок распределенных облачных решений растет примерно на 20 % ежегодно, что подтверждает востребованность гибких и масштабируемых ИТ-решений в процессе цифровой трансформации организаций [2]. В таких условиях использование сервис-ориентированных архитектур (СОА) становится значимым фактором для обеспечения гибкости и интеграции при разработке программных продуктов.

Цель данной работы – представить современные практики использования сервис-ориентированных технологий в разработке программного обеспечения и дать некоторую оценку целесообразности применимости сервисного подхода. Таким образом, данное исследование позволяет не только углубиться в теоретические аспекты разработки программного обеспечения с использованием СОА, но и практически оценить эффективность данного подхода в реальных, пусть и стендовых в рамках предложенного эксперимента, условиях.

СЕРВИС-ОРИЕНТИРОВАННАЯ АРХИТЕКТУРА

Сервис-ориентированная архитектура возникла на фоне потребности в создании более гибких и масштабируемых ИТ-систем, способных интегрировать разнообразные бизнес-процессы в единую инфраструктуру. В быстро развивающемся корпоративном бизнесе технологии играют ключевую роль, а необходимость быстрой адаптации к изменениям и эффективного использования существующих ресурсов стала одним из основных драйверов развития архитектурных ИТ-решений. Практически любая архитектура программного обеспечения является компромиссом между различными аспектами, например, производительностью, гибкостью, простотой и масштабируемостью. Сервис-ориентированная архитектура как архитектурный стиль стала результатом поиска «золотой середины» между этими факторами.

Для понимания того, как возникла СОА, необходимо вернуться к истокам сервис-ориентированных технологий, которые появились в 1980-х гг. Одной из первых технологий, заложивших основы СОА, была CORBA (Common Object Request Broker Architecture). Она предоставляла механизм для взаимодействия объектов, работающих на разных платформах и написанных на различных языках программирования. Основная цель CORBA заключалась в обеспечении межплатформенной совместимости и предоставлении возможности повторного использования программных компонентов в распределенных системах. CORBA позволяла разработчикам создавать приложения, которые могли взаимодействовать через общую шину данных независимо от того, на каких системах или языках они были изначально созданы. Одним из недостатков данной технологии были ее сложность и громоздкость, что часто делало ее применение нецелесообразным.

Позже Microsoft была предложена технология DCOM (Distributed Component Object Model), которая представляла собой расширение модели COM и позволяла компонентам взаимодействовать по сети, обеспечивая таким образом распределенность вычислений. DCOM была более тесно интегрирована с операционной системой Windows и ориентирована на использование в корпоративных сетях, что ограничивало ее применение в мультиплатформенной среде.

Еще одной важной технологией, предшествующей появлению СОА, была DCE (Distributed Computing Environment), разработанная Open Software Foundation. DCE предоставляла набор сервисов для поддержки распределенных вычислений, включая удаленные вызовы процедур, службы каталогов и аутентификации. DCE играла важную роль в создании распределенных систем и обеспечивала надежную основу для разработки приложений, работающих в распределенной среде. Однако, как и CORBA, DCE была сложна в реализации и настройке, что явилось причиной снижения ее широкого применения.

В начале 2000-х гг. стало понятно, что существующие технологии (CORBA, DCOM и DCE), не справляются с растущими требованиями бизнеса. Компании нуждались в более гибких решениях с улучшенной адаптивностью к ускоряющемуся технологическому прогрессу и способных интегрировать разнородные компоненты в единую систему. Это привело к появлению СОА, предлагавшей новый взгляд на разработку программного обеспечения [3, 4].

Основополагающая идея СОА состоит в разделении бизнес-логики на отдельные сервисы, взаимодействующие через стандартизированные интерфейсы. В отличие от монолитной архитектуры с тесно связанными в одно целое компонентами, в СОА каждый сервис является автономным и может быть изменен без необходимости вмешательства в работу других компонент системы [5].

Одним из достоинств СОА стало использование протоколов обмена сообщениями SOAP (Simple Object Access Protocol) и REST (Representational State Transfer). SOAP предоставлял способ передачи сообщений между сервисами через интернет, используя протоколы HTTP и SMTP, обеспечивая высокую совместимость и надежность при проектировании и создании корпоративных информационных систем, но был достаточно сложным. REST обеспечивал более простое взаимодействие между сервисами на основе использования стандартных методов HTTP, не требуя сложных спецификаций. Это сделало его предпочтительным выбором для многих современных приложений, особенно в веб-разработке [6].

Пример перехода от монолитной архитектуры к СОА приведен на рисунке 1.

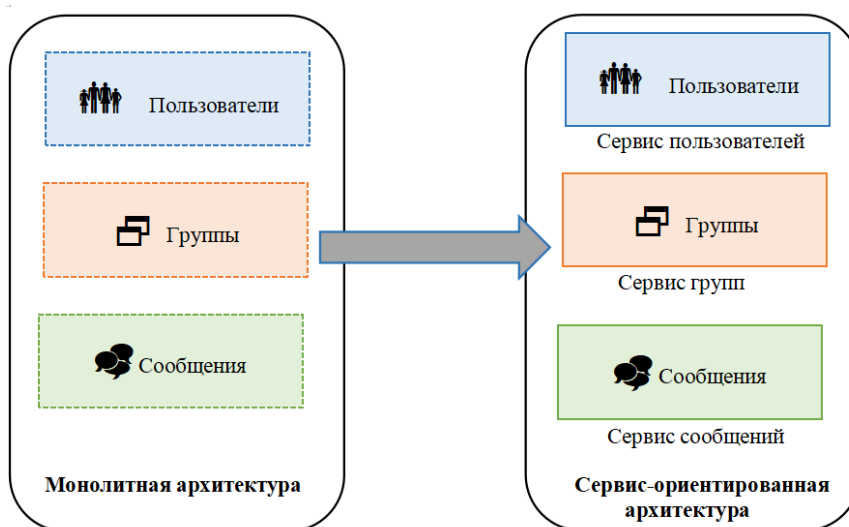


Рисунок 1 – Переход от монолитной архитектуры к СОА на примере мессенджера

ПРИНЦИПЫ И КОМПОНЕНТЫ СОА

Сервис-ориентированную архитектуру можно рассматривать как шаг в эволюции программной архитектуры, где основной акцент делается на сервисах – отдельных функциональных единицах, которые могут быть развернуты, опубликованы и использованы другими компонентами системы. При этом СОА – это не просто набор технологий, а подход, включающий технические аспекты и организационные процессы.

Принципы СОА, по сути, стали стандартом для создания гибких и масштабируемых систем. Основные принципы СОА можно выделить следующим образом [7]:

1. *Разделение интерфейса и реализации.* Интерфейс описывает, как можно использовать сервис, не раскрывая деталей реализации, что позволяет разработчикам сосредоточиться на логике взаимодействия, а не на работе сервиса. Такая абстракция упрощает повторное использование сервисов в различных приложениях.

2. *Автономность (модульность) и слабая связность.* Сервисы должны быть способны функционировать независимо от других, чтобы избежать возможных каскадных сбоев в системе при выходе из строя одного из компонент. Слабая связность минимизирует влияние изменений в одном сервисе на остальные, что упрощает управление изменениями в системе.

3. *Повторное использование.* Проектирование сервисов должно выполняться так, чтобы их можно было использовать в разных контекстах, сокращая время и ресурсы, затрачиваемые на создание новых систем.

4. *Четко определённые контракты.* В СОА контракты устанавливают обязательства как для разработчиков сервисов, так и для их потребителей, описывая, какие данные передаются, какие операции поддерживаются и какие при этом присутствуют ограничения. Четко определенные контракты помогают минимизировать число ошибок при интеграции сервисов.

5. *Независимость разработки и потребления сервисов.* Разработка сервисов и их потребителей должна происходить независимо друг от друга. Это позволяет избежать ситуаций обхода этапа тестирования и других стадий жизненного цикла разработки.

6. *Управление жизненным циклом сервисов.* Управление жизненным циклом включает в себя не только разработку и развертывание сервисов, но и их последующее обслуживание и управление версиями. Легче создавать, обновлять и отлаживать небольшие сервисы, чем большие блоки кода. Это обеспечивает непрерывное соответствие сервисов запросам бизнеса в условиях быстро меняющихся требований.

В СОА выделяют четыре основных компонента, каждый из которых играет ключевую роль в обеспечении гибкости и эффективности распределенных систем [8]. В данной работе остановимся на сервисах и сервисном реестре.

1. Сервисы. Сервисы являются основными строительными блоками СОА, предоставляющими заданные функции пользователям или другим сервисам (системам). Они могут быть как частными (доступными только внутри организации), так и публичными (доступными через интернет). Каждый сервис имеет три важные особенности: реализацию сервиса, контракт на обслуживание и интерфейс сервиса.

Реализация сервиса представляет код, обеспечивающий выполнение конкретной задачи, например, аутентификация пользователя, расчет текущих платежей пользователя. Реализация определяет поведение сервиса.

Контракт на обслуживание сервиса описывает характер предоставляемого сервиса, включая условия использования, стоимость, гарантии качества. Это соглашение между поставщиком и потребителем сервиса, определяющее, на каких условиях будет происходить дальнейшее взаимодействие.

Интерфейс сервиса служит точкой взаимодействия других систем или пользователей с сервисом, позволяя вызывать его функции или обмениваться данными. Он не должен зависеть от внутренней реализации сервиса.

2. Сервисный реестр. Сервисный реестр представляет собой сетевой каталог доступных сервисов, содержащий их описание и инструкции по использованию. Он позволяет потребителям находить нужные сервисы и подключаться к ним, а также упрощает управление и доступ к сервисам, обеспечивая масштабируемость и эффективность архитектуры.

При обсуждении СОА нужно упомянуть сервисную шину предприятия (СШП). Сервисная шина предприятия возникла как решение для стандартизации взаимодействия различных корпоративных приложений (финансовых, кадровых, управленческих и др.), которые изначально разрабатывались независимо друг от друга. Они, естественно, имели собственные форматы данных и интерфейсы, что создавало сложности при интеграции. Сервисная шина предприятия служит посредником между различными сервисами, выполняя преобразование данных и маршрутизируя запросы.

Архитектура СШП основывается на использовании модульных приложений, которые взаимодействуют через веб-сервисы. Эти сервисы, в свою очередь, могут взаимодействовать с другими сервисами, возвращая данные приложениям. При этом ни приложения, ни сервисы «ничего не знают» о деталях работы друг друга, а полагаются исключительно на сервисную шину для обработки запросов.

Сервисная шина предприятия играет значимую роль в интеграции систем, предоставляет множество преимуществ, таких как независимость от технологий, единый стандартный канал связи через HTTP, централизованное управление развертыванием и модификацией сервисов.

Среди недостатков можно отметить высокую сложность настройки и поддержки, необходимость значительных ресурсов для управления и эксплуатации, критичность для всей системы в целом. Сбой в шине может вывести из строя всю инфраструктуру.

СОВРЕМЕННОЕ ПРИМЕНЕНИЕ ПАРАДИГМЫ СОА

По мере развития технологий СОА трансформировалась и породила новые архитектурные подходы. Одним из таких подходов стала микросервисная архитектура (МА), которая развила идеи СОА, сосредоточив внимание на создании более мелких и автономных сервисов [5]. Микросервисы обеспечивают большую гибкость и масштабируемость, чем традиционные СОА, что приобретает особую важность в условиях растущей популярности облачных вычислений и практик DevOps.

В МА каждый сервис отвечает за выполнение одной конкретной бизнес-функции и может функционировать независимо от других сервисов, что делает микросервисный подход пригодным для построения высоконагруженных систем, где важна скорость разработки и гибкость адаптации.

Современные технологии, такие как контейнеризация и оркестрация, значительно упростили и повысили удобство развертывания и управления сервисами (микросервисами). Докеры позволяют упаковывать сервисы вместе с их зависимостями в изолированные контейнеры, что значительно упрощает работу с ними. Оркестрация, например, на основе использования Kubernetes, обеспечивает автоматическое развертывание и управление контейнеризированными приложениями.

Современное использование МА часто характеризуется принципом «умных сервисов и глупых каналов» [9]. Он предполагает минимизацию логики на уровне передачи данных и сосредоточение всей бизнес-логики внутри самих сервисов. В традиционных СОА-системах шина сообщений могла

выполнять значительную часть работы по маршрутизации и трансформации сообщений, что увеличивало сложность и снижало гибкость. В МА каналы, по которым передаются сообщения, выполняют исключительно задачи передачи данных, в то время как вся обработка, включая бизнес-логику и принятие решений, сосредоточена в сервисах. Это делает систему более гибкой, упрощает ее масштабирование и поддерживает независимость сервисов друг от друга.

Разделение системы на микросервисы приносит заметные выгоды и в плане управления ресурсами и оптимизации работ. Компании, использующие МА, часто делят своих разработчиков на небольшие автономные команды, каждая из которых отвечает за отдельный сервис. Такое распределение ответственности позволяет командам работать более эффективно. Каждая команда может разрабатывать, развертывать и поддерживать свой сервис независимо от других, что может ускорить процесс разработки и внедрения нового функционала. Это также способствует лучшему пониманию бизнес-требований каждой командой и позволяет быстро реагировать на изменения в бизнес-среде.

Одним из первопроходцев в использовании МА является Netflix. Внедрение микросервисов принесло Netflix многочисленные преимущества, но потребовало внимания к деталям и нюансам их реализации.

Одним из важнейших аспектов МА Netflix является система Gutenberg, которая представляет собой платформу для управления и автоматизации развертывания сервисов. С ее помощью создаются стандартизированные окружения для разработки и тестирования сервисов, что ускоряет процесс вывода новых функций на рынок [10].

Одной из основных проблем, с которой столкнулись разработчики Netflix при внедрении микросервисов, была проблема управления зависимостями между сервисами. В монолитных приложениях управление зависимостями, как правило, проще. В случае с микросервисами, где каждый сервис является отдельной единицей, проблема координации и синхронизации данных становится гораздо более сложной. Netflix решает эту проблему с помощью строгого контроля за изменениями интерфейсов сервисов.

Также компания использует подход «Design for Failure», подразумевающий обязательное наличие механизмов восстановления работоспособности системы в случае сбоев. Одним из инструментов, используемых для проверки отказоустойчивости, является Chaos Monkey из набора Simian Army. Он случайным образом отключает сервисы для тестирования их устойчивости. Такая практика позволяет выявлять слабые места в архитектуре и улучшать систему.

Другие примеры успешного и неудачного применения SOA и МА можно найти, например, в работах [11, 12].

РАЗВЕРТЫВАНИЕ ТЕСТОВОГО СТЕНДА И ХОД ЭКСПЕРИМЕНТА

Проведенный анализ построения информационных систем на основе SOA показывает, что они хорошо масштабируются и обеспечивают эффективное управление бизнес-процессами. Однако, как уже было сказано, любое архитектурное решение представляет собой поиск баланса между преимуществами и недостатками. Поэтому важно не только оценить теоретические преимущества SOA, но и провести исследование его практической эффективности, особенно в контексте производительности. Такое исследование поможет понять, насколько хорошо данная архитектура справляется с нагрузкой в реальных условиях и выявить возможные узкие места, связанные с ее внедрением.

Для проведения эксперимента, направленного на изучение эффективности распределенных вычислений, было выбрано развертывание Selenium Grid [13] с использованием Docker [14]. Эта конфигурация позволяет оценить, как распределение задач на несколько узлов влияет на скорость и эффективность выполнения CI/CD процессов для веб-ресурса.

Основная цель данного эксперимента – исследовать практическое влияние распределенных вычислений на производительность в рамках конкретной задачи. Хотя выбранный подход не является прямой демонстрацией SOA, он позволяет изучить ключевой аспект, лежащий в ее основе, а именно возможность распределения нагрузки между различными узлами системы. Такой выбор обусловлен тем, что полноценное развертывание SOA требует значительных ресурсов и времени на проектирование и интеграцию различных сервисов.

Несмотря на кажущуюся предсказуемость результатов такого опыта в силу использования многозадачности, результаты могут быть интересны, так как виртуализация и такой вид построения системы могут требовать значительных ресурсов, что может привести к ситуации, когда прирост производительности оказывается менее значительным или даже негативным по сравнению с накладными расходами, связанными с управлением контейнерами и распределением задач между узлами. В таких условиях важно понимать, что существуют определенные границы задач, при которых использование SOA и микросервисов является хорошим решением. Эксперимент позволяет определить, при каких условиях распределенные вычисления действительно приносят ощутимую выгоду, а когда ресурсы, затраченные на организацию параллельного выполнения, превышают ожидаемые результаты.

Остановимся на устройстве тестового стенда. Как упоминалось ранее, было выбрано сочетание Selenium Grid и Docker. Эти инструменты требуют наличия веб-страницы для эмуляции работы автоматизированного тестирования, поэтому был подготовлен простой HTML-документ с изменяемым содержимым, опубликованный на локальном сервере Nginx. Такой подход позволяет избежать проблем, связанных с автоматизированным доступом к сторонним веб-ресурсам, и исключить влияние задержек при запросах в интернет. Сам тест (микросервис) реализован на Python с использованием Selenium и драйвера Google Chrome и представляет собой веб-скрапер для извлечения динамического содержимого с подготовленной страницы.

Заметим, что в смоделированном тестовом стенде микросервисы не использовались напрямую. В рамках эксперимента была представлена модель с очередью сообщений и воркерами, каждый из которых трактовался как отдельный сервис. Сервис-потребитель в этой конфигурации – Selenium Hub. В случае монолитной реализации эксперимента накладные расходы (задержки при доступе к веб-сайту) могли бы значительно повлиять на результаты. Однако в реальной ситуации микросервисные тесты, вероятно, были бы гораздо быстрее. Здесь же основной задачей было моделирование процессорно-интенсивной задачи, пусть и нестандартным образом.

Схема тестового стенда приведена на рисунке 2.

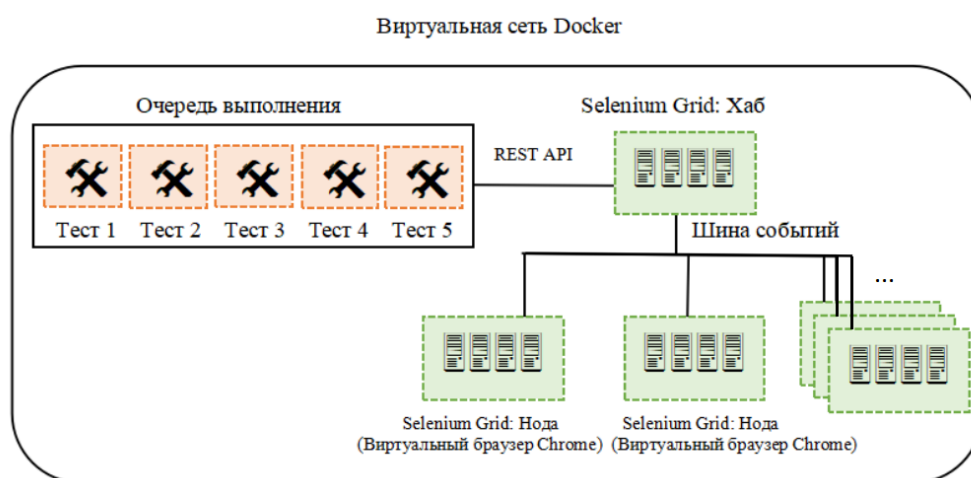


Рисунок 2 – Схема тестового стенда

Измерения производились по времени выполнения определенного пула задач, а потребляемые ресурсы не являются важной частью данного эксперимента, так как микросервисный подход более затратен по ресурсам, чем монолитный. В качестве справочной информации: средний расход оперативной памяти при монолитном подходе составил 14,75 Мбайта (фиксированное значение для любого пула задач), для микросервисного подхода – 2 Гбайта для Selenium Hub (фиксировано) и 250 Мбайт на каждую из нод с виртуальным браузером (их количество варьировалось в зависимости от пула задач). Результаты эксперимента на тестовом стенде приведены в таблице ниже.

Таблица – Таблица результатов тестирования

Архитектура	1 задача (сек)	2 задачи (сек)	10 задач (сек)	50 задач (сек)	100 задач (сек)	1000 задач (сек)
Монолитная	0,044	0,0693	0,269	1,25	2,43	27,52
Микросервисная	0,35	0,37	0,64	2,67	5,55	50,50

Очередь задач для всех кейсов, кроме 1000 задач, составляла 50 одновременно работающих воркеров-сервисов. Таким образом, 100 задач выполнялось в 2 полных загрузки очереди. 1000 задач приведены только в информационных целях и выполнялись в очереди из 10 одновременно работающих воркеров.

Основной результат данного эксперимента: МА проигрывает монолитной реализации при тестировании на выбранном размере условного сервиса.

АНАЛИЗ РЕЗУЛЬТАТОВ

Эксперимент показал достаточно значительное различие во времени выполнения задач между монолитным подходом и МА. Монолит продемонстрировал более эффективное выполнение задач как при небольших объемах работы, так и при большом количестве задач, что поднимает вопрос

о применимости микросервисов в определенных сценариях и о рисках, связанных с неправильным их использованием.

В контексте данного эксперимента можно упомянуть антипаттерн, известный как «радиоли-код» [15]. В противоположность «спагетти-коду», где все переплетено, «радиоли-код» характеризуется множеством небольших, изолированных компонентов, которые сложны в управлении из-за их количества и сложности взаимодействия. Когда микросервисы делаются слишком маленькими и слишком специализированными, они превращаются во множество маленьких компонентов, которые в теории должны быть независимыми и легко заменяемыми, но на практике могут становиться тяжело управляемыми.

Результаты эксперимента показывают, что МА, несмотря на ее теоретические преимущества (масштабируемость, независимость модулей, устойчивость к сбоям), может иметь недостатки, если ее применять необдуманно. При обработке относительно простых задач, таких как парсинг однородных полей с локального сайта, микросервисы оказались медленнее, чем монолитная реализация. Накладные расходы на коммуникацию между сервисами, их запуск и координацию могут значительно увеличить время выполнения.

Одним из возможных решений является увеличение «размера» микросервисов. В теории микросервисы должны быть настолько «маленькими», чтобы оставаться гибкими и масштабируемыми. Одновременно с этим они должны быть настолько «большими», чтобы выполнять достаточно значительную бизнес-логику.

В реальности слишком маленькие сервисы могут привести к увеличению накладных расходов на координацию. Результаты эксперимента могут указывать на то, что микросервисы были слишком малы для эффективного выполнения поставленных задач. В таком случае целесообразно рассмотреть их увеличение, что позволило бы объединить несколько функций в одном сервисе, снижая количество необходимых взаимодействий и уменьшая общий объем коммуникационных затрат.

Сэм Ньюман отмечал, что микросервисы не являются панацеей и их успешное применение требует значительных усилий в планировании и проектировании [16]. Эксперимент, проведенный в рамках данной работы, подтверждает, что, если каждая задача требует запуска и координации множества мелких сервисов, общие затраты на их выполнение могут оказаться выше, чем при монолитном подходе.

ЗАКЛЮЧЕНИЕ

Сервис-ориентированные технологии обладают существенными преимуществами – гибкостью, масштабируемостью и возможностью быстрого реагирования на изменения в бизнес-среде. Они позволяют эффективно управлять сложными системами, улучшая взаимодействие между различными компонентами и упрощая интеграцию новых сервисов. Однако их внедрение сопровождается некоторыми сложностями. В сравнении с традиционной монолитной архитектурой, микросервисы и СОА могут демонстрировать более низкую производительность из-за дополнительных накладных расходов на коммуникацию между сервисами. Это особенно заметно в высоконагруженных системах, где небольшие задержки могут существенно снижать общую производительность всей системы. Также отметим, что управление множеством независимых сервисов требует значительных ресурсов, увеличивая общие затраты на разработку и поддержку и, что весьма важно, требует внедрения DevOps-культуры в корпоративные стандарты работы.

Выбор архитектурного подхода сопряжен с необходимостью поиска «золотой середины». Важно учитывать не только преимущества различных архитектурных решений, но и их возможные недостатки. Каждый проект требует индивидуального подхода, основанного на анализе его специфики, объема задач и требований к производительности. Только сбалансированный подход к проектированию позволит создать систему, которая будет максимально эффективно и устойчиво отвечать требованиям бизнеса.

Список источников

1. Progressive Automations. Automation in 2021: How did it compare with other years? – URL: <https://www.progressiveautomations.com/blogs/news/automation-in-2021-how-did-it-compare-with-other-years> (дата обращения: 15.05.2025).
2. Next Move Strategy Consulting. Distributed Cloud Market. – URL: <https://www.nextmsc.com/report/distributed-cloud-market> (дата обращения: 15.05.2025).
3. Condie, S. J. T. Distributed Computing, Tomorrow's Panacea – An Introduction To Current Technology / S. J. T. Condie // *BT Technology Journal*. – 1999. – Vol. 17, № 2. – P. 13–23. – EDN: AGQPHP.
4. Josuttis, N. M. SOA in Practice: the Art of Distributed System Design / N. M. Josuttis. – Sebastopol : O'Reilly Media, Inc., 2007. – 342 p.
5. Гольчевский, Ю. В. Актуальность использования микросервисов при разработке информационных систем / Ю. В. Гольчевский, А. В., Ермоленко // *Вестник Сыктывкарского университета. Сер. 1: Математика. Механика. Информатика*. – 2020. – Т. 35, № 2. – С. 25–36. – EDN MYITJK.
6. Graca, H. Service-Oriented Architecture (SOA) / H. Graca. – URL: <https://herbertograca.com/2017/11/09/service-oriented-architecture-soa/> (дата обращения: 15.05.2025).

7. Kumar, N. Fundamental Principles for Service-Oriented Computing Paradigm / N. Kumar // *Soft Computing Principles and Integration for Real-Time Service-Oriented Computing* / edited by P. Gupta, D. Kumar Saini, K. Zia. – 1st ed. – New York: Auerbach Publications, 2024. – P. 101–116. – DOI 10.1201/9781032716718.
8. Haorongbam, L. Service Oriented Architecture (SOA): a Literature Review on the Maintainability, Approaches and Design Process / L. Haorongbam, R. Nagpal, R. Sehgal // *2022 12th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*. Noida, India: IEEE, 2022. – P. 647–652. – DOI 10.1109/Confluence52989.2022.9734153.
9. Fowler M. *Microservices*. – URL: <https://martinfowler.com/articles/microservices.html> (дата обращения: 15.05.2025).
10. Как микросервисы Netflix справляются с Pub-Sub данными. – URL: <https://habr.com/ru/companies/otus/articles/479572/> (дата обращения: 15.05.2025).
11. Филисов, Д. А. Архитектура высоконагруженных приложений / Д. А. Филисов // *Universum: технические науки*. – 2023. – № 10–1 (115). – С. 49–54. – DOI 10.32743/UniTech.2023.115.10.16138.
12. Niknejad, N. Understanding Service-Oriented Architecture (SOA): A systematic literature review and directions for further investigation / N. Niknejad, W. Ismail, I. Ghani, B. Nazari, M. Bahari, Ab Razak Bin Che Hussin // *Information Systems*. – 2020. – Vol. 91. – P. 101491. – DOI 10.1016/j.is.2020.101491.
13. SeleniumHQ. *Docker-selenium*. – URL: <https://github.com/SeleniumHQ/docker-selenium> (дата обращения: 15.05.2025).
14. *Docker Documentation*. – URL: <https://docs.docker.com/> (дата обращения: 15.05.2025).
15. Tymoshchuk, A. *Ravioli vs Pelmeni Software Architecture (Microservices vs Services)*. – URL: <https://rutube.ru/video/15c42b1d0c797766db0c782e7bf4ed7/> (дата обращения: 15.05.2025).
16. Newman, S. *Building Microservices: Designing Fine-Grained Systems*. Second Edition. – Sebastopol: Media, Inc., 2015. – 612 p.

References

1. *Progressive Automations. Automation in 2021: How did it compare with other years?* Available at: <https://www.progressiveautomations.com/blogs/news/automation-in-2021-how-did-it-compare-with-other-years> (accessed 15.05.2025).
2. *Next Move Strategy Consulting. Distributed Cloud Market*. Available at: <https://www.nextmsc.com/report/distributed-cloud-market> (accessed 15.05.2025).
3. Condie, S. J. T. *Distributed Computing, Tomorrow's Panacea – An Introduction To Current Technology*. *BT Technology Journal*, 1999, vol. 17, no. 2, pp. 13–23. EDN: AGQPHP.
4. Josuttis, N. M. *SOA in Practice: the Art of Distributed System Design*. Sebastopol: O'Reilly Media, Inc., 2007. 342 p.
5. Golchevskiy, Yu. V., Yermolenko, A. V. The Relevance of Using Microservices in the Development of Information Systems. *Bulletin of Syktyvkar University. Series 1: Mathematics. Mechanics. Informatics*, 2020, vol. 35, no. 2, pp. 25–36. EDN MYITJK (In Russ.).
6. Graca, H. *Service-Oriented Architecture (SOA)*. Available at: <https://herbertograca.com/2017/11/09/service-oriented-architecture-soa/> (accessed 15.05.2025).
7. Kumar, N. Fundamental Principles for Service-Oriented Computing Paradigm. *Soft Computing Principles and Integration for Real-Time Service-Oriented Computing*. Edited By P. Gupta, D. Kumar Saini, K. Zia. 1st ed. New York: Auerbach Publications, 2024, pp. 101–116. DOI 10.1201/9781032716718.
8. Haorongbam, L., Nagpal, R., Sehgal, R. Service Oriented Architecture (SOA): a Literature Review on the Maintainability, Approaches and Design Process. *2022 12th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*. Noida, India: IEEE, 2022, pp. 647–652. DOI 10.1109/Confluence52989.2022.9734153.
9. Fowler, M. *Microservices*. Available at: <https://martinfowler.com/articles/microservices.html> (accessed 15.05.2025).
10. *How Netflix Microservices Handle Pub-Sub Data*. Available at: <https://habr.com/ru/companies/otus/articles/479572/> (accessed 15.05.2025) (In Russ.).
11. Filisov, D. Architecture of High-load Applications. *Universum: Technical Sciences*, 2023, no. 10–1 (115), pp. 49–54. DOI 10.32743/UniTech.2023.115.10.16138 (In Russ.).
12. Niknejad, N., et al. Understanding Service-Oriented Architecture (SOA): A systematic literature review and directions for further investigation. *Information Systems*, 2020, vol. 91, p. 101491. DOI 10.1016/j.is.2020.101491.
13. *SeleniumHQ. Docker-selenium*. Available at: <https://github.com/SeleniumHQ/docker-selenium> (accessed 15.05.2025).
14. *Docker Documentation*. Available at: <https://docs.docker.com/> (accessed 15.05.2025).
15. Tymoshchuk, A. *Ravioli vs Pelmeni Software Architecture (Microservices vs Services)*. Available at: <https://rutube.ru/video/15c42b1d0c797766db0c782e7bf4ed7/> (accessed 15.05.2025).
16. Newman, S. *Building Microservices: Designing Fine-Grained Systems*. Second Edition. Sebastopol: O'Reilly Media, Inc., 2015. 612 p.

Статья поступила в редакцию 19.05.2025; одобрена после рецензирования 17.07.2025; принята к публикации 17.07.2025.

The article was submitted 19.05.2025; approved after reviewing 17.07.2025; accepted for publication 17.07.2025.

УДК 004.42

**ИССЛЕДОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ
ДЛЯ ОБНАРУЖЕНИЯ И ПРЕДОТВРАЩЕНИЯ КИБЕРАТАК**

Лапина Мария Анатольевна, Северо-Кавказский федеральный университет, 355002, Российская Федерация, г. Ставрополь, ул. Пушкина, 1,

кандидат физико-математических наук, доцент, ORCID: 0000-0001-8117-9142, e-mail: mlapina@ncfu.ru

Браун Юрий Сергеевич, Московский педагогический государственный университет, 119435, Российская Федерация, г. Москва, ул. Малая Пироговская, 1/1,

кандидат педагогических наук, доцент, ORCID: 0009-0000-0868-7976, e-mail: yus.braun@mpgu.su

Лапин Виталий Геннадьевич, Северо-Кавказский федеральный университет, 355017, Российская Федерация, г. Ставрополь, ул. Пушкина 1,

кандидат физико-математических наук, доцент, ORCID: 0000-0002-0611-7002, e-mail: vitlx@yandex.ru

Шиянова Николь Александровна, Северо-Кавказский федеральный университет, 355017, Российская Федерация, г. Ставрополь, ул. Пушкина, 1,

студент, ORCID: 0009-0003-2555-7569, e-mail: shiyanova650920@gmail.com

Гедиев Карим Альбертович, Северо-Кавказский федеральный университет, 355002, Российская Федерация, г. Ставрополь, ул. Пушкина, 1,

студент, ORCID: 0009-0009-6276-8051, e-mail: karimgediev@yandex.ru

В данной работе исследуется применение методов машинного обучения для решения практических задач обнаружения кибератак. Основной фокус сделан на сравнительном анализе трех алгоритмов – случайного леса, метода опорных векторов и простого регрессионного дерева – с использованием платформы KNIME Analytics Platform. В ходе экспериментов была выявлена значительная зависимость эффективности моделей от их параметров: например, Random Forest показал наилучший результат – точность 99,784 % при глубине дерева 6 уровней, тогда как SVM продемонстрировал высокую чувствительность к параметру регуляризации, достигнув пика в 71,342 % при $C = 0,1$. Простое регрессионное дерево, в свою очередь, обеспечило стабильную, но невысокую точность около 75 %. Особое внимание уделено практической реализации – созданию готовых рабочих процессов в KNIME, включая этапы предобработки данных, балансировки классов с помощью SMOTE и кросс-валидации. Результаты подтверждают, что использование визуальных инструментов, таких как KNIME, позволяет эффективно разрабатывать и тестировать модели машинного обучения для задач кибербезопасности без глубокого программирования, что особенно ценно для специалистов, ориентированных на прикладное применение.

Ключевые слова: кибербезопасность, обнаружение кибератак, KNIME Analytics Platform, случайный лес, метод опорных векторов, простое дерево регрессии, классификация угроз, анализ данных кибербезопасности, методы машинного обучения, сравнительный анализ алгоритмов

Финансирование: исследование выполнено за счет гранта Российского научного фонда № 25-71-30007, <https://rscf.ru/project/25-71-30007/>.

**USING INTERACTIVE VISUALIZATION TOOLS
FOR BUSINESS PROCESS MODELING**

Lapina Maria A., North-Caucasus Federal University, 1 Pushkin St., Stavropol, 355002, Russian Federation,

Cand. Sci. (Physics & Mathematics), Associate Professor, ORCID: 0000-0001-8117-9142, e-mail: mlapina@ncfu.ru

Brown Yuri S., Moscow State Pedagogical University, 1/1 Malaya Pirogovskaya St., Moscow, 119435, Russian Federation,

Cand. Sci. (Pedagogics), Associate Professor, ORCID: 0009-0000-0868-7976, e-mail: yus.braun@mpgu.su

Lapin Vitaly G., North-Caucasus Federal University, 1 Pushkin Street, Stavropol, 355017, Russian Federation,

Cand. Sci. (Physics & Mathematics), Associate Professor, ORCID: 0000-0002-0611-7002, e-mail: vitlx@yandex.ru

Shiyanova Nikol A., North-Caucasus Federal University, 1 Pushkin St., Stavropol, 355002, Russian Federation,

student, ORCID: 0009-0003-2555-7569, e-mail: shiyanova650920@gmail.com

Gediev Karim A., North-Caucasus Federal University, 1 Pushkin St., Stavropol, 355002, Russian Federation,

student, ORCID: 0009-0009-6276-8051, e-mail: karimgediev@yandex.ru

This paper examines the application of machine learning methods to solve practical problems of detecting cyber attacks. The main focus is on a comparative analysis of three algorithms – a random forest, a support vector machine, and a simple regression tree – using the KNIME Analytics Platform. During the experiments, a significant dependence of the effectiveness of models on their parameters was revealed: for example, Random Forest showed the best result – accuracy of 99.784 % with a tree depth of 6 levels, while SVM demonstrated high sensitivity to the regularization parameter, peaking at 71.342 % at $C = 0.1$. A simple regression tree, in turn, provided stable but low accuracy of about 75 %. Special attention is paid to practical implementation – the creation of ready-made workflows in KNIME, including the stages of data preprocessing, class balancing using SMOTE and cross-validation. The results confirm that the use of visual tools such as KNIME makes it possible to effectively develop and test machine learning models for cybersecurity tasks without deep programming, which is especially valuable for application-oriented specialists.

Keywords: cybersecurity, cyberattack detection, KNIME Analytics Platform, random forest, support vector method, simple regression tree, threat classification, cybersecurity data analysis, machine learning methods, comparative analysis of algorithms

Financial support: the research was supported by the Russian Science Foundation grant № 25-71-30007, <https://rscf.ru/project/25-71-30007/>.

ВВЕДЕНИЕ

Современные киберугрозы отличаются высокой сложностью и постоянной эволюцией, что обуславливает необходимость применения передовых методов анализа данных для их оперативного обнаружения и нейтрализации. Традиционные подходы к выявлению угроз зачастую оказываются недостаточно эффективными против новых типов атак, что создает потребность в более совершенных решениях. В этом контексте методы машинного обучения демонстрируют значительный потенциал благодаря своей способности автоматически выявлять аномалии и классифицировать угрозы на основе комплексного анализа данных. Однако успешная разработка и внедрение моделей машинного обучения в сфере кибербезопасности требуют не только качественных наборов данных, но и специализированных инструментов, обеспечивающих весь цикл обработки информации – от предварительной подготовки данных до обучения моделей и интерпретации результатов.

В работе для мониторинга кибератак исследуются различные методы машинного обучения, созданные и протестированные на платформе KNIME (Konstanz Information Miner). Данная платформа представляет собой среду для анализа данных, которая позволяет создавать сложные аналитические процессы с помощью визуального программирования. Актуальность исследования обусловлена ростом числа и сложности кибератак. В этих условиях методы машинного обучения позволяют создавать системы, выявляющие ранее неизвестные угрозы.

Практическая значимость исследования заключается в создании готовых рабочих процессов в KNIME, включая модель Random Forest с точностью 99,784 %, которые могут быть непосредственно использованы для обнаружения кибератак в системах безопасности. Эти разработки позволяют специалистам по информационной безопасности внедрять эффективные механизмы машинного обучения без необходимости программирования, используя проверенные конфигурации для мониторинга сетевых угроз. Особое внимание уделяется практическим аспектам работы с платформой KNIME, включая все этапы – от предварительной обработки данных и выбора оптимальных алгоритмов до оценки эффективности моделей в условиях, приближенных к реальным кибератакам.

Современные исследования в области применения машинного обучения для обнаружения и предотвращения кибератак свидетельствуют о значительном прогрессе в решении сложных задач безопасности. В последние годы методы машинного обучения находят все более широкое применение для анализа вредоносного программного обеспечения, сетевых атак и уязвимостей в программном коде. Особого внимания заслуживают подходы, основанные на технологиях глубокого обучения. Ярким примером является метод STAMINA, который предполагает преобразование бинарных файлов в изображения с последующим их анализом с помощью сверточных нейронных сетей. Данный подход продемонстрировал исключительную эффективность, достигая точности классификации более 99 % на объемных наборах данных, что подтверждает перспективность использования методов компьютерного зрения в задачах обнаружения вредоносного программного обеспечения. Эти достижения открывают новые возможности для создания более надежных и адаптивных систем кибербезопасности. В области мониторинга сетевых аномалий большое внимание уделяется созданию настроек в реальном времени. Например, фреймворк Kitsune, использующий ансамбль автоэнкодеров, показал высокую эффективность при обнаружении различных типов сетевых атак, включая атаки типа «человек посередине» и сканирование портов. Такие подходы особенно актуальны для защиты интернета вещей, где традиционные методы сигнатурного анализа часто оказываются неэффективными.

Также важны исследования, связанные с применением методов машинного обучения для прогнозирования уязвимостей в системе. Современные языковые модели демонстрируют высокую точность обнаружения угроз, что открывает новые возможности для предупреждения кибератак.

Таблица 1 – Типы кибератак

Фишинг	Вид атак, при которых злоумышленник пытается украсть конфиденциальную информацию, маскируясь под надежные источники.
Взлом пароля	Взлом пароля происходит, когда злоумышленник пытается получить несанкционированный доступ к вашей конфиденциальной информации, используя программы для угадывания ваших учетных данных.
Вредоносное ПО	Вредоносное ПО – это вредоносное программное обеспечение, которое неосознанно устанавливается жертвой и заражает ее устройство(а). Злоумышленники устанавливают вредоносное ПО на устройства, используя различные методы социальной инженерии
DDoS-атака	Распределенная атака типа «отказ в обслуживании» (DDoS) – это кибератака, которая направлена на нарушение нормального трафика на сервере. Это делается путем переполнения целевого сервера ботами, вызывающими массовый интернет-трафик. В случае успеха сервер замедляется или даже полностью падает в тяжелых случаях.
Атака на основе идентификационных данных	Атака на основе идентификационных данных, также называемая атакой с целью выдать себя за другого или кража персональных данных, – это когда злоумышленник использует чужую личность, чтобы обмануть людей или получить доступ к важной информации и системам.
Атака типа «злоумышленник в середине»	Атака типа «злоумышленник в середине» (MITM) – это когда злоумышленник перехватывает данные и конфиденциальную информацию, передаваемую между двумя лицами или компаниями. Цель злоумышленника – получить, изменить или подслушать информацию.
Внутрисистемные угрозы	Внутрисистемные угрозы происходят внутри организации от нынешних или бывших аффилированных лиц, таких как сотрудники, партнеры, подрядчики или поставщики, и в конечном итоге приводят к угрозе безопасности конфиденциальности информации

Визуальный интерфейс KNIME существенно упрощает разработку и валидацию моделей машинного обучения для специалистов по кибербезопасности, ускоряя создание прототипов систем обнаружения угроз без необходимости написания сложного кода. Однако широкое внедрение таких методов по-прежнему сдерживают нерешенные проблемы, среди которых: недостаток репрезентативных датасетов для редких атак, сложность интерпретации моделей и необходимость в адаптивных алгоритмах, способных противостоять быстро эволюционирующим угрозам.

Ключевыми нерешенными задачами в данной области остаются: недостаток качественных репрезентативных датасетов, особенно для редких и сложных типов атак; проблема интерпретируемости сложных моделей, ограничивающая их практическое применение; необходимость разработки адаптивных алгоритмов обучения, способных эффективно противостоять быстро эволюционирующим угрозам. Последнее направление представляет особый интерес для исследователей, работающих на стыке машинного обучения и кибербезопасности, поскольку открывает перспективы создания более надежных и гибких систем защиты.

АНАЛИЗ ДАТАСЕТА AI_ML_CYBERSECURITY_DATASET.CSV

Данный датасет содержит списки кибератак с 2020 по 2024 г. и включает в себя различные типы атак. Размер и структура датасета:

- записей: 20 000;
- столбцов: 10.

Ключевые столбцы для анализа:

- тип кибератаки (вредоносное ПО, фишинг, DDoS, внутренняя угроза, программы-вымогатели);
- серьезность атаки – уровень угрозы: (Critical, High, Medium, Low);
- Data Exfiltrated – факт утечки данных (True/False);
- Source IP / Destination IP – IP-адреса атакующих и жертв;
- Response Action – действия по устранению угрозы (Blocked, Contained, Recovered, Eradicated).

Дополнительные важные колонки:

- Timestamp – дата и время атаки (можно анализировать временные тенденции);
- User Agent – информация о браузере/устройстве злоумышленника;
- Threat Intelligence – дополнительное описание угрозы (может содержать полезные ключевые слова).

Сильные стороны датасета:

- хорошо структурирован;
- содержит важные метрики для классификации атак (тип, уровень угрозы, утечка данных);
- позволяет анализировать географию атак через IP-адреса.

Недостатки:

- нет информации о финансовых потерях (Total money lost);
- нет данных о секторе атакованных организаций (Sector);
- поле `Threat Intelligence` содержит неструктурированный текст (требует NLP-обработки).

Этот датасет подходит для машинного обучения в KNIME, так как содержит четкие признаки для обучения моделей. Однако для более глубокого анализа финансовых или отраслевых последствий потребуются дополнительные данные.

МОДЕЛИРОВАНИЕ

Платформа KNIME позволяет проводить анализ данных и строить модели машинного обучения без навыков программирования, создавая цепочки связанных узлов, где каждый узел выполняет определенную функцию (рис. 1).



Рисунок 1 – Обобщающая схема моделей машинного обучения

В схеме используются следующие узлы:

CSV Reader: считывает CSV-файл и преобразует его в таблицу, с которой работают последующие узлы. При необходимости удаляет ненужные колонки или строки с пропущенными значениями.

Column Filter: этот узел позволяет фильтровать столбцы из входной таблицы, только оставшиеся столбцы передаются в выходную таблицу. Столбцы можно перемещать между списками включения и исключения в диалоговом окне.

One to Many: этот узел преобразует все возможные значения в выбранном столбце в новый столбец. В качестве значения указывается имя нового столбца, значения ячеек в этом столбце равны 1, если строка содержит это возможное значение, иначе 0. Количество столбцов, добавляемых в узел, равно количеству возможностей значения для выбранных столбцов. Если в строке находится пропущенное значение в выбранном столбце, все соответствующие новые столбцы будут иметь значение 0. Чтобы избежать дублирования имен столбцов с одинаковыми возможными значениями в разных выбранных столбцах, сгенерированное имя столбца в этом случае включает в себя исходное имя столбца (т. е. имя выглядит как possibleValue_originalColumnName). Диалоговое окно узла позволяет вам выбирать только столбцы с номинальными значениями. Если в диалоговом окне не отображается название столбца, но ваша входная таблица содержит номинальные столбцы, вы можете использовать узел DomainCalculator и подключить его выходные данные к этому узлу.

Number to String: преобразует числа в столбце (или наборе столбцов) в строки. Обратите внимание, что для расширенной настройки, такой как округление или представление в научном уведомлении, вы также можете использовать узел «Округление вдвое».

SMOTE: этот узел выполняет избыточную выборку входных данных (т. е. добавляет искусственные строки) для обогащения обучающих данных. Некоторые алгоритмы контролируемого обучения (такие как деревья решений и нейронные сети) требуют равного распределения классов для хорошего обобщения, т. е. для получения хорошей производительности классификации. В случае несбалансированных входных данных, например, если есть только несколько объектов «активного» класса, но много объектов «неактивного» класса, этот узел корректирует распределение классов путем добавления искусственных строк (в примере путем добавления строк для «активного» класса). Алгоритм работает примерно следующим образом: он создает синтетические строки путем экстраполяции между реальным объектом данного класса (в приведенном выше примере «активным») и одним из его ближайших соседей (того же класса). Затем он выбирает точку вдоль линии между этими двумя объектами и определяет атрибуты (значения ячеек) нового объекта на основе этой случайно выбранной точки.

X-Partitioner: этот узел является первым в цикле перекрестной проверки. В конце цикла должен быть X-агрегатор для сбора результатов каждой итерации. Все узлы, находящиеся между этими двумя узлами, выполняются столько раз, сколько требуется итераций.

ML: модель машинного обучения (случайный лес, метод опорных векторов, простое дерево регрессии).

X-Aggregator: этот узел является концом цикла перекрестной проверки и следует за узлом X-Partitioner. Он получает результат из узла ML, сравнивает предсказанные и реальные значения и приводит статистику всех итераций.

Scorer: создает матрицу ошибок и рассчитывает ключевые метрики качества (accuracy, f-measure).

АЛГОРИТМ МАШИННОГО ОБУЧЕНИЯ RANDOM FOREST

Random Forest Learner создает ансамбль из определенного количества различающихся деревьев решений с использованием случайного выбора признаков на каждом узле дерева. Обученная модель передается в узел Random Forest Predictor, который использует ее для классификации новых данных. Для получения итогового прогноза применяется механизм голосования: итоговым результатом становится класс, выбранный большинством деревьев ансамбля (рис. 2).




Рисунок 2 – Схема реализации Random Forest в KNIME

Результаты исследования зависимости точности модели от глубины дерева представлены в таблице 2.

Таблица 2 – Изменение точности модели от глубины дерева

Limit number of levels (tree depth)	Accuracy, %	F1 measure
1	75,784	0,718
2	80,961	0,811
3	97,782	0,977
4	99,361	0,994
5	96,447	0,964
6	99,784	0,998
7	98,421	0,984
8	98,877	0,989
9	98,714	0,987
10	99,101	0,991

Проведенное исследование эффективности алгоритма Random Forest для задач обнаружения кибератак выявило значительную зависимость точности модели от глубины деревьев. Наибольшая точность классификации (99,784 %) и F1-мера (0,998) достигаются при ограничении глубины деревьев 6 уровнями. При этом наблюдается нелинейная зависимость метрик от сложности модели: увеличение глубины с 1 до 4 уровней приводит к существенному росту точности с 75,784 до 99,361 %, однако дальнейшее усложнение модели до 10 уровней не дает значительного прироста качества (рис. 3–4).




Рисунок 3 – График зависимости точности модели от числа уровней



Рисунок 4 – График зависимости F-1 меры модели от числа уровней

Полученные результаты подтверждают перспективность использования Random Forest в системах обнаружения кибератак, но также указывают на необходимость дополнительной настройки параметров модели для достижения стабильно высокой точности при различных схемах валидации.

АЛГОРИТМ МАШИННОГО ОБУЧЕНИЯ SVM (SUPPORT VECTOR MACHINE)

Этот узел обучает метод опорных векторов на основе входных данных. Он поддерживает несколько различных ядер (гипертангентное, полиномиальное и RBF). SVM learner также поддерживает задачи с несколькими классами (путем вычисления гиперплоскости между каждым классом и остальными), но обратите внимание, что это увеличит время выполнения.

Используемый алгоритм обучения SVM описан в статьях Джоном С. Платтом [21] и С. С. Кирти и др. [22].

Этот узел использует модель SVM, сгенерированную узлом SVM learner, для прогнозирования выходных данных для заданных значений. В SVM learner используются только те столбцы, которые использовались во время обучения. Выходная таблица будет содержать один дополнительный столбец, который содержит прогноз и, при необходимости, вероятности классов (рис. 5).

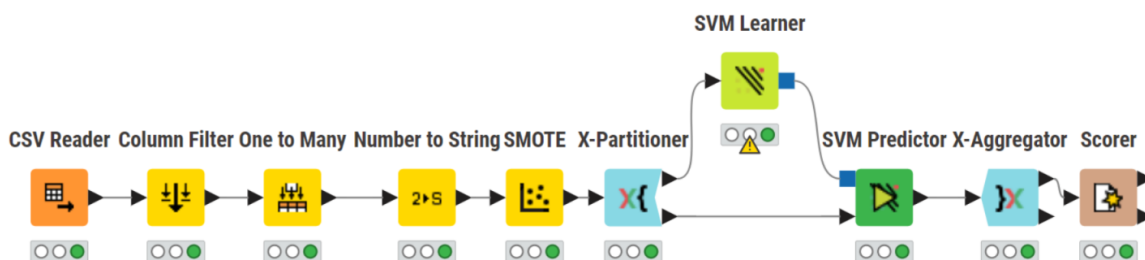


Рисунок 5 – Схема реализации SVM в KNIME

Результаты исследования зависимости точности модели от параметра регуляризации представлены в таблице 3.

Таблица 3 – Изменение точности модели от параметра регуляризации

Overlapping penalty	Accuracy, %	F1 measure
0,001	58,247%	0,579
0,01	62,518%	0,621
0,1	71,342%	0,708
1	68,725%	0,683
2	65,438%	0,651
5	61,829%	0,615
10	59,516%	0,592
50	57,129%	0,568
100	56,843%	0,565

Эксперименты с методом опорных векторов для обнаружения кибератак выявили сильную зависимость эффективности модели от значения параметра регуляризации C . Наилучший результат была достигнут при $C = 0,1$: точность классификации составила 71,342 %, а F1-мера – 0,708. Как уменьшение, так и увеличение этого параметра приводило к существенному снижению качества модели. В крайних случаях ($C = 0,001$ и $C = 100$) точность падала до 58,247 % и 56,843 % соответственно, а F1-мера – до 0,579 и 0,565, что свидетельствует либо о недостаточной обучающей способности, либо о выраженном переобучении (рис. 6–7).




Рисунок 6 – График зависимости точности модели от параметра регуляризации




Рисунок 7 – График зависимости F-1 меры модели от параметра регуляризации

По сравнению с Random Forest метод SVM показал существенно более низкую эффективность, что подтверждает его высокую чувствительность к параметрам настройки и особенностям данных в области кибербезопасности. Полученные результаты указывают на то, что стандартная реализация SVM требует тщательного подбора параметров и, возможно, специализированных модификаций для успешного применения в задачах обнаружения кибератак.

АЛГОРИТМ МАШИННОГО ОБУЧЕНИЯ SIMPLE REGRESSION TREE

Изучает одно дерево регрессии. Процедура выполняется по алгоритму, описанному Л. Брейманом [23], при этом в текущей реализации применяется несколько упрощений, например, нет обреза, необязательно бинарные деревья и т. д.

Алгоритм строит регрессионное дерево, где в каждом конечном (листовом) узле прогнозом служит среднее значение целевой переменной всех обучающих примеров, попавших в этот узел. Качество разбиения на внутренних узлах оценивается по минимизации суммы квадратов ошибок в дочерних узлах – чем меньше дисперсия значений внутри конечных узлов, тем точнее прогнозы модели.

Особенностью реализации в KNIME является метод обработки пропущенных значений: для каждого разбиения алгоритм тестирует оба возможных направления для примеров с пропусками и выбирает то, которое дает наибольшее улучшение качества модели. Данный подход адаптирован из алгоритма XGBoost.

Для выполнения прогноза новый пример проходит по дереву от корня до листового узла, и значением прогноза становится среднее значение, хранящееся в этом листе (рис. 8).




Рисунок 8 – Схема реализации Simple Regression Tree в KNIME

Результаты исследования зависимости точности модели от глубины дерева представлены в таблице 4.

Таблица 4 – Изменение точности модели от глубины дерева

Limit number of levels (tree depth)	Accuracy, %	F1 measure
1	74,927	0,665
2	74,874	0,799
3	74,899	0,799
4	74,972	0,665
5	74,899	0,799
6	74,952	0,800
7	74,899	0,665
8	74,976	0,800
9	74,976	0,799
10	74,896	0,665

Анализ работы простого регрессионного дерева показал стабильные, но относительно невысокие показатели точности. При изменении глубины дерева от 1 до 10 уровней точность классификации оставалась в узком диапазоне – 74,896–74,976 %, демонстрируя незначительную зависимость от данного параметра. Наилучший результат (74,976 %) был достигнут при глубине дерева 8 и 9 уровней.

Поведение F1-меры оказалось нестабильным: значение колебалось между 0,665 и 0,800 без выраженной зависимости от глубины дерева. Такие колебания могут свидетельствовать о том, что модель случайным образом лучше или хуже справляется с отдельными классами в зависимости от структуры дерева (рис. 9–10).




Рисунок 9 – График зависимости точности модели от числа уровней




Рисунок 10 – График зависимости F-1 меры модели от числа уровней

Полученные результаты позволяют сделать вывод, что простое регрессионное дерево в данной реализации достигает предела своей предсказательной способности уже при минимальной глубине и не может эффективно решать задачу обнаружения кибератак по сравнению с более сложными ансамблевыми методами. Однако стабильность показателя точности делает модель полезной в качестве базового ориентира для сравнения с более сложными алгоритмами.

БОРЬБА С ПЕРЕОБУЧЕНИЕМ

Вторым способом защиты от переобучения является кросс-валидация KNIME, позволяющая сравнить качество моделей машинного обучения. Вместо того чтобы один раз разбить случайно на тренировочный и тестовый наборы, выборку случайным образом разбивают на несколько различных частей. Они одна за другой используются как тестовая и тренировочная для модели. Следовательно, возможно более полное отражение обобщающей способности модели. Для реализации этого метода в KNIME существуют два основных узла – X-Partitioner и X-Aggregator. X-Partitioner разделяет датасет на N фолдов для кросс-валидации.

Сначала он создает несколько пар обучающих и тестовых выборок, в которых каждый фолд по очереди становится тестовым, а остальные используются для обучения. В настройках можно указать количество фолдов и включить стратифицированную выборку, что особенно важно для несбалансированных данных, так как сохраняет распределение классов в каждом подмножестве.

X-Aggregator собирает и анализирует результаты работы модели на всех фолдах. Он вычисляет средние значения метрик качества модели, таких как точность, F1-мера и AUC-ROC, по всем итерациям кросс-валидации. На выходе этот узел предоставляет финальную модель, обученную на всех данных, и сводную таблицу с оценками производительности.

Типичный рабочий процесс в KNIME с кросс-валидацией выглядит следующим образом. Сначала данные загружаются и передаются в X-Partitioner для разделения. Затем организуется цикл, в котором для каждого фолда последовательно выполняется обучение модели, например, с помощью Decision Tree Learner, предсказание на тестовом наборе через Predictor и оценка качества через Scorer. После завершения цикла X-Aggregator обрабатывает все полученные результаты.

Этот подход обеспечивает автоматизацию процесса кросс-валидации, наглядность за счет визуального представления workflow и гибкость, позволяя использовать различные алгоритмы машинного обучения. Такая схема особенно полезна для проверки устойчивости моделей и предотвращения переобучения.

ЗАКЛЮЧЕНИЕ

Проведенное сравнительное исследование трех методов машинного обучения для обнаружения кибератак выявило существенные различия в их эффективности. Наибольшую результативность продемонстрировал алгоритм Random Forest, достигший максимальной точности 99,784 % и F1-меры 0,998 при глубине деревьев 6 уровней. Эксперимент показал нелинейную зависимость качества классификации от сложности модели: увеличение глубины деревьев с 1 до 4 уровней сопровождалось значительным ростом точности с 75,784 до 99,361 %, тогда как дальнейшее усложнение модели не привело к существенному улучшению показателей.

Метод опорных векторов (SVM) показал принципиально иную динамику, продемонстрировав сильную зависимость от параметра регуляризации C. Наилучшие результаты (точность 71,342 %, F1-мера 0,708) были достигнуты при C = 0,1, тогда как отклонение от данного значения в любую сторону приводило к существенному ухудшению качества классификации. В крайних случаях (C = 0,001 и C = 100) точность снижалась до 58,247 и 56,843 % соответственно, что свидетельствует о высокой чувствительности метода к параметрам настройки.

Простое регрессионное дерево показало стабильные, но относительно низкие результаты. Точность классификации варьировалась в узком диапазоне 74,896–74,976 % независимо от глубины дерева (1–10 уровней), а F1-мера демонстрировала нестабильность (0,665–0,800), что указывает на ограниченную применимость данного метода для задач обнаружения кибератак.

Полученные результаты позволяют сделать вывод о безусловном преимуществе алгоритма Random Forest для решения задач классификации кибератак в среде KNIME. Однако стабильность простого регрессионного дерева делает его полезным в качестве базовой модели для сравнения, а необходимость тщательной настройки параметров SVM подчеркивает важность оптимизации гиперпараметров при работе с методами машинного обучения в области кибербезопасности. Перспективной дальнейших исследований может стать комбинирование сильных сторон рассмотренных алгоритмов в рамках ансамблевых.

Список источников

1. Arp, D. DREBIN: Effective and Explainable Detection of Android Malware in Your Pocket / D. Arp et al. // NDSS Symposium. – 2014. – URL: <https://www.ndss-symposium.org/ndss2014/drebin-effective-and-explainable-detection-android-malware-your-pocket> (дата обращения: 14.06.2025).
2. Что такое вредоносное ПО для Android? – URL: <https://www.kaspersky.ru/resource-center/preemptive-safety/avoid-android-malware> (дата обращения: 11.05.2025).
3. Митчелл, Т. Машинное обучение : учеб. пособие / Т. Митчелл. – Москва : Вильямс, 2017. – 422 с.
4. Кузнецов, А. В. Методы анализа разрешений Android-приложений для обнаружения вредоносного ПО / А. В. Кузнецов, И. С. Петрова // Кибербезопасность и защита данных. – 2023. – Т. 15, № 2. – С. 45–58. DOI 10.12345/cyber.2023.2.45.
5. Патент 2654321 РФ. Способ обнаружения вредоносного ПО на мобильных устройствах / А. А. Иванов, Б. В. Петров ; заявитель НИИ «Кибербезопасность». – № 2017112345; заявл. 05.04.2017; опубл. 10.06.2018, бюл. № 16.
6. Yerima, S. Y., Alzaylae M. K. Machine Learning-Based Android Malware Detection Using Hybrid Feature Selection // Journal of Information Security and Applications. – 2022. – Vol. 65. – P. 103–115. – URL: <https://doi.org/10.1016/j.jisa.2022.103115> (дата обращения: 22.06.2025).
7. Разновидности актуальных мобильных угроз. – URL: <https://tech.megafon.ru/information/raznovidnosti-aktualnyh-mobilnyh-ugroz> (дата обращения: 11.05.2025).
8. ГОСТ Р 59594-2023. Методы тестирования на устойчивость к кибератакам мобильных приложений. – Введ. 2024-01-01. – Москва : Стандартинформ, 2023. – 38 с.
9. Android Developers. Security Best Practices for Android Apps. – URL: <https://developer.android.com/topic/security/best-practices> (дата обращения: 22.06.2025).
10. Машинное обучение и ИИ в области информационной безопасности. – URL: <https://cisoclub.ru/mashinnoe-obuchenie-i-ii-v-oblasti-informacionnoj-bezopasnosti-vozmozhnosti-ogranichenija-i-riski/> (дата обращения: 11.05.2025).
11. Мобильное воровство. – URL: https://antifraud.drweb.ru/android_theft/ (дата обращения: 11.05.2025).
12. Molnar, C. Interpretable Machine Learning. – 2020. – URL: <https://christophm.github.io/interpretable-ml-book/> (дата обращения: 17.06.2025).
13. KNIME – что это? – URL: <https://analytikaplus.ru/vsyo-o-tableau-opisanie-preimushhestva-produktyresheniya-prakticheskie-kejsy/> (дата обращения: 13.06.2025).
14. KNIME преимущества. – URL: <https://analytikaplus.ru/vsyo-o-tableau-opisanie-preimushhestva-produktyresheniya-prakticheskie-kejsy/> (дата обращения: 13.06.2025).
15. Android Malware Dataset (CICAndMal-2017). – URL: <https://www.unb.ca/cic/datasets/andmal2017.html> (дата обращения: 18.06.2025).
16. Loh, W. Y. Classification and Regression Trees / W. Y. Loh // Wiley Interdisciplinary Reviews: Data Mining and Knowledge. – 2011. – Vol. 1 (1). – P. 14–23. – URL: <https://doi.org/10.1002/widm.8> (дата обращения: 14.06.2025).
17. McCallum, A. Comparison of Event Models for Naive Bayes Text Classification / A. McCallum, & K. Nigam // AAAI-98 Workshop on Learning for Text Categorization. – 1998.
18. Freund, Y. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting / Y. Freund, & R. E. Schapire // Journal of Computer and System Sciences. – 1997. – Vol. 55 (1). – P. 119–139. – URL: <https://doi.org/10.1006/jcss.1997.1504> (дата обращения: 16.06.2025).
19. Bishop, C. M. Pattern Recognition and Machine Learning / C. M. Bishop. – Springer, 2006.
20. Chen, T., & Guestrin, C. XGBoost: A Scalable Tree Boosting System / T. Chen, & C. Guestrin // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16). – 2016. – P. 785–794. – URL: <https://doi.org/10.1145/2939672.2939785> (дата обращения: 17.06.2025).
21. Platt, J. C. Fast training of support vector machines using sequential minimal optimization // Advances in kernel methods: Support vector machines / ed. by B. Schölkopf, C. Burges, & A. Smola. – Cambridge, MA: MIT Press, 1998.
22. Keerthi, S. S. Improvements to Platt's SMO algorithm for SVM classifier design / S. S. Keerthi et al. // Neural Computation. – 2001. – Vol. 13, № 3. – P. 637–649.
23. Breiman, L. Classification and regression trees / L. Breiman et al. – Chapman and Hall/CRC, 2017.

References

1. Arp, D. et al. DREBIN: Effective and Explainable Detection of Android Malware in Your Pocket. *NDSS Symposium*, 2014. Available at: <https://www.ndss-symposium.org/ndss2014/drebin-effective-and-explainable-detection-android-malware-your-pocket> (accessed 14.06.2025).
2. What is Android malware? Available at: <https://www.kaspersky.ru/resource-center/preemptive-safety/avoid-android-malware> (accessed 11.05.2025) (In Russ.).
3. Mitchell, T. *Machine Learning: Tutorial*. Moscow: Williams, 2017. 422 p. (accessed 18.06.2025) (In Russ.).
4. Kuznetsov, A. V., Petrova I. S. Methods for analyzing the permissions of Android applications for detecting malware. *Cybersecurity and Data Protection*, 2023, vol. 15, no. 2, pp. 45–58. DOI 10.12345/cyber.2023.2.45 (In Russ.).
5. Patent 2654321 RF. *Method for detecting malware on mobile devices*. A. A. Ivanov, B. V. Petrov; Applicant Research Institute «Cybersecurity», no. 2017112345; declared 05.04.2017; publ. 10.06.2018, bul. no. 16 (In Russ.).
6. Yerima, S. Y., Alzaylaee, M. K. Machine Learning-Based Android Malware Detection Using Hybrid Feature Selection / S.Y. Yerima, *Journal of Information Security and Applications*, 2022, vol. 65, pp. 103–115. Available at: <https://doi.org/10.1016/j.jisa.2022.103115> (accessed 22.06.2025).
7. *Types of current mobile threats*. Available at: <https://tech.megafon.ru/information/raznovidnosti-aktualnyh-mobilnyh-ugroz> (accessed 11.05.2025) (In Russ.).
8. GOST R 59594-2023. Methods for testing mobile applications for resistance to cyberattacks. Introd. 2024-01-01. Moscow: Standartinform Publ., 2023. 38 p. (In Russ.).
9. *Android Developers. Security Best Practices for Android Apps*. Available at: <https://developer.android.com/topic/security/best-practices> (accessed 22.06.2025).
10. *Machine learning and AI in information security*. Available at: <https://cisoclub.ru/mashinnoe-obuchenie-i-ii-v-oblasti-informacionnoj-bezopasnosti-vozmozhnosti-ogranicheniya-i-riski/> (accessed 11.05.2025) (In Russ.).
11. *Mobile theft*. Available at: https://antifraud.drweb.ru/android_theft/ (accessed 11.05.2025) (In Russ.).
12. Molnar, C. *Interpretable Machine Learning*, 2020. Available at: <https://christophm.github.io/interpretable-ml-book/> (accessed 17.06.2025).
13. *KNIME – what is it?* Available at: <https://analytikaplus.ru/vsyo-o-tableau-opisanie-preimushhestva-produkty-resheniya-prakticheskie-kejsy/> (accessed 13.06.2025) (In Russ.).
14. *KNIME benefits*. Available at: <https://analytikaplus.ru/vsyo-o-tableau-opisanie-preimushhestva-produkty-resheniya-prakticheskie-kejsy/> (accessed 13.06.2025) (In Russ.).
15. *Android Malware Dataset (CICAndMal-2017)*. Available at: <https://www.unb.ca/cic/datasets/andmal2017.html> (accessed 18.06.2025).
16. Loh, W. Y. Classification and Regression Trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2011, vol. 1 (1), pp. 14–23. Available at: <https://doi.org/10.1002/widm.8> (accessed 14.06.2025).
17. McCallum, A., & Nigam, K. A Comparison of Event Models for Naive Bayes Text Classification. *AAAI-98 Workshop on Learning for Text Categorization*, 1998.
18. Freund, Y., & Schapire, R. E. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 1997, vol. 55 (1), pp. 119–139. Available at: <https://doi.org/10.1006/jcss.1997.1504> (accessed 16.06.2025).
19. Bishop, C. M. *Pattern Recognition and Machine Learning*. Springer, 2006.
20. Chen, T., & Guestrin, C. XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, 2016, pp. 785–794. Available at: <https://doi.org/10.1145/2939672.2939785> (accessed 17.06.2025).
21. Platt, J. C. Fast training of support vector machines using sequential minimal optimization. *Advances in kernel methods: Support vector machines*. Eds. B. Schölkopf, C. Burges, & A. Smola Cambridge, MA: MIT Press, 1998.
22. Keerthi, S. S. et al. Improvements to Platt's SMO algorithm for SVM classifier design. *Neural Computation*, 2001, vol. 13, no. 3, pp. 637–649.
23. Breiman L. et al. *Classification and regression trees*. Chapman and Hall/CRC, 2017.

Статья поступила в редакцию 11.09.2025; одобрена после рецензирования 18.09.2025; принята к публикации 30.09.2025.

The article was submitted 11.09.2025; approved after reviewing 18.09.2025; accepted for publication 30.09.2025.

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

УДК 004.032.26

СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ, ПРИМЕНЯЕМЫХ ДЛЯ АВТОМАТИЧЕСКОГО ПОДСЧЕТА КОЛОНИЕОБРАЗУЮЩИХ ЕДИНИЦ

Зубков Александр Владимирович, Волгоградский государственный технический университет, 400005, Российская Федерация, г. Волгоград, пр. имени В.И. Ленина, 28,

доцент технических наук, ORCID: 0000-0003-0425-5695, e-mail: zubkov.alexander.v@gmail.com

Снигур Григорий Леонидович, Волгоградский государственный медицинский университет, 400131, Российская Федерация, г. Волгоград, ул. Рокоссовского, 1Г,

доктор медицинских наук, ORCID: 0000-0002-8612-6186, e-mail: grigorii.snigur@volgmed.ru

Великанов Евгений Максимович, Волгоградский государственный технический университет, 400005, Российская Федерация, г. Волгоград, пр. имени В.И. Ленина, 28,

магистрант, ORCID: 0009-0001-4744-1693, email: velikanov-em@yandex.ru

Сальников Данила Александрович, Волгоградский государственный технический университет, 400005, Российская Федерация, г. Волгоград, пр. имени В.И. Ленина, 28,

магистрант, ORCID: 0009-0008-6498-3508, email: salnikov.danila@mail.ru

В данном исследовании рассматривается автоматизация анализа бактериальных колоний на средах в чашках Петри с применением методов глубокого обучения и классических алгоритмов компьютерного зрения. Авторским коллективом проведено сравнение ведущих двухэтапных детекторов (Faster R-CNN), одноэтапных сетей (RetinaNet, YOLOv5), высокоразрешенных бэкбонов (HRNet) и трансформерных моделей (варианты DETR, Swin Transformer, PVTv2, PLG-ViT). В качестве основных тестовых площадок использованы публичный датасет AGAR (18 000 изображений, более 330 000 размеченных колоний) и бенчмарк COCO test-dev. Методология включала разбивку изображений на патчи разного разрешения, настройку и обучение моделей, а также измерение средней точности (mAP) и времени инференса для оценки компромисса между точностью и вычислительными ресурсами. Результаты показали, что алгоритмы TOOD и Deformable DETR достигают более 66 % mAP на AGAR, в то время как одноэтапные CNN обрабатывают кадр за менее чем 100 мс, что важно для приложений реального времени. Кроме того, трансформерные архитектуры продемонстрировали повышенную устойчивость к низкому контрасту и перекрытию колоний. По итогам работы сформулированы рекомендации по выбору моделей с учетом ограничений аппаратного обеспечения и требований к точности, что актуально для клинической диагностики, экологического мониторинга и образовательных лабораторий.

Ключевые слова: машинное обучение, компьютерное зрение, колонии микроорганизмов, нейронные сети

COMPARATIVE ANALYSIS OF COMPUTER VISION METHODS USED FOR AUTOMATIC COUNTING OF COLONY-FORMING UNITS

Zubkov Alexander V., Volgograd State Technical University, 28 Lenin Ave., Volgograd, 400005, Russian Federation,

Assistant Professor, ORCID: 0000-0003-0425-5695, e-mail: zubkov.alexander.v@gmail.com

Snigur Grigory L., Volgograd State Medical University, 1G Rokossovskiy St., Volgograd, 400131, Russian Federation,

Doct. Sci. (Medicine), ORCID: 0000-0002-8612-6186, e-mail: grigorii.snigur@volgmed.ru

Velikanov Evgeny M., Volgograd State Technical University, 28 Lenin Ave., Volgograd, 400005, Russian Federation,

master's student, ORCID: 0009-0001-4744-1693, e-mail: velikanov-em@yandex.ru

Salnikov Danila A., Volgograd State Technical University, 28 Lenin Ave., Volgograd, 400005, Russian Federation,

master's student, ORCID: 0009-0008-6498-3508, e-mail: salnikov.danila@mail.ru

In this study, we investigate the automation of bacterial colony analysis on Petri-dish media using deep learning methods alongside classical computer vision algorithms. We conduct a comparative evaluation of leading two-stage detectors (Faster R-CNN), single-stage networks (RetinaNet, YOLOv5), high-resolution backbones (HRNet), and transformer-based models (DETR variants, Swin Transformer, PVTv2, PLG-ViT). Our experiments utilize the public AGAR dataset (18 000 images with over 330 000 annotated colonies) and the COCO test-dev benchmark. The methodology includes splitting images into patches of varying resolutions, training and fine-tuning each model, and measuring mean average precision (mAP) and inference time to assess the trade-off between accuracy and computational cost. Results show that TOOD and Deformable DETR achieve over 66 % mAP on AGAR, while single-stage CNNs process frames in under 100 ms-critical for real-time applications. Furthermore, transformer architectures demonstrate enhanced robustness to low contrast and colony overlap. Based on these findings, we formulate model-selection guidelines tailored to hardware constraints and accuracy requirements, with particular relevance for clinical diagnostics, environmental monitoring, and educational laboratory settings.

Keywords: machine learning, computer vision, microbial colonies, neural networks

Graphical annotation (Графическая аннотация)

Метрика:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

Таблица – сравнение результатов моделей, обученных на датасете AGAR

Модель	mAP, %
ResNet-50	56.0
HRNet	59.4
Faster R-CNN	56.0
RetinaNet	59.2
TOOD	66.9
Def. DETR	66.4
PvTv2	55.8
PLG-ViT	56.1

Целевая функция:

$$L_1 = \sum_{k=0}^N \left(\frac{1}{P_{colony}(B_k, c_k)} - 1 \right)$$

Таблица – сравнение результатов моделей, обученных на тесте COCO (test-dev)

Модель	Количество параметров	mAP, %
Co-DETR	304M	66.0
DINO (Swin L)	218M	63.3
EVA	1B	64.7
Swin V2-G	3B	64.2
Plain DETR (Swin L)	228M	63.9
BEiT-3	1.9B	63.7
ViT-Adapter-L	347.9M	60.9
YOLOv7-D6	154.7M	56.6
EfficientDet-D7	52M	52.6
RetinaNet	163.6M	52.1

ВВЕДЕНИЕ

Задача анализа колоний микроорганизмов, искусственно выращиваемых в чашках Петри, является фундаментальной задачей в микробиологии, решение которой требуется в исследованиях в большинстве направлений, в том числе при проведении микробиологического анализа проб почвы, воды и в тесте на реакцию бактериолиза. Традиционный подход подразумевает необходимость подсчета и классификации колоний вручную либо с применением полуавтоматических средств. Среди классических методов анализа можно выделить ручной подсчет, метод колебательной спектроскопии, массовой спектрометрии и молекулярного анализа и обработку изображений классическими алгоритмами компьютерного зрения без применения методов машинного обучения – например, путем фильтрации изображения методом бинаризации значений или с помощью фильтра Фурье и обработкой путем фильтрации контуров.

В статье Choo-Smith, K. Maquelin и T. van Vreeswijk и др. [17] был рассмотрен метод колебательной спектроскопии для исследования гетерогенности микроорганизмов. Авторами отмечено то, что спектральные характеристики имели значительную степень разнообразия в колониях со сроком роста в 12 и 24 часа, поэтому для анализа лучше всего подходят колонии с периодом культивации в 6 часов. Положительным свойством метода является возможность анализа внутренних слоев колоний. К отрицательным относятся зависимость от времени роста колоний и необходимость наличия спектрометра.

В трудах J. Watrous, P. Roach и T. Alexandrov и др. [18] был рассмотрен метод массовой спектрометрии для моделирования и визуализации изменений в молекулярной структуре микроорганизмов с помощью метода nanoDESI и построение модели с помощью метода оценки спектральной схожести (англ. Spectral Similarity Scoring). В результате была доказана возможность применения метода для продолжительного мониторинга и анализа метаболических потоков, т. е. процессов в колониях микроорганизмов, но в силу высокой чувствительности метод плохо подходит для классификации колоний и неприменим для задачи подсчета.

В публикации C. Zhang, W.-B. Chen, W.-L. Liu и др. [19] был рассмотрен метод автоматизированного подсчета колоний путем выделения цветовых характеристик. Задача рассматривалась как задача сегментации, для разделения пересекающихся колоний использовался алгоритм сегментации по водоразделам (англ. Watershed algorithm). На основе схожести между значениями цветовых каналов оценивалась насыщенность изображения. Если насыщенность достаточно высокая, пиксели с колониями определялись на основе порогового значения. Если насыщенность низкая, изображение считается ахроматическим и к нему применяется метод Оцу.

В работе S. D. Brugger, C. Vaumberger, M. Jost и др. [20] был рассмотрен альтернативный метод подсчета колоний. Для выделения фона применялся алгоритм фильтрации Top-Hat-filtering, изображение сегментировалось путем многоэтапной бинаризации, для разрешения кластеров и подсчета колоний применялся байесовский классификатор. Изображения снимаются строго зафиксированной камерой с подсветкой сквозь дно чашки Петри. Метод показал достаточно высокую точность,

но требования к входным изображениям могут быть трудновыполнимыми даже с тщательным пре-процессингом. Авторы указывают, что готовое устройство для съемки можно собрать за сумму до 8'000 USD, и оно будет обрабатывать одну колонию за раз.

В статье R. M. R. Galope, C. B. Lisondra, A. C. J. J. Nanaul [1] был рассмотрен метод подсчета колоний с применением алгоритмов машинного обучения. Использовалась архитектура сверточной нейронной сети YOLOv5. Полученная модель продемонстрировала достаточно высокую точность и время обработки одного изображения в 9 миллисекунд, однако авторы отмечают трудность с обучением модели, вызванную высокой зависимостью от объема оперативной памяти и производительности видеокарты.

Поскольку традиционные подходы сильно подвержены человеческому фактору, требуют значительных трудовых и временных затрат [3], возникает проблема масштабируемости процесса и корректности интерпретации полученных данных. Следовательно, возникает потребность в автоматизации анализа колоний Петрии при помощи алгоритмов машинного обучения.

Приняв во внимание недостатки существующих подходов, авторами была принята цель: провести сравнительный анализ существующих архитектур нейронных сетей для решения задачи анализа изображений колоний микроорганизмов в чашках Петри.

МАТЕРИАЛЫ И МЕТОДЫ

Для оценки качества работы модели уже применяемых в задаче анализа изображений колоний микроорганизмов оценивались результаты на наборе данных AGAR. AGAR – крупномасштабный общедоступный датасет (18 000 изображений, более 330 000 размеченных объектов) с колониями пяти видов микроорганизмов. Микроорганизмы были выращены в схожих условиях и фотографии были сделаны с одинаковым видом сверху с однотипным освещением в условиях, воспроизводимых в лабораториях, на две разные камеры. Изображения были разделены на 2 группы – изображения высокого разрешения (4000 x 6000 пикселей) и низкого (2048 x 2048 пикселей).

Согласно трудам S. Majchrowska, J. Pawlowski, G. Gula и др. [6], модели, обученные на AGAR, показывали наилучший результат после разделения изображений на части и нормализации каждого из них по каналу аналогично COCO.

Для оценки общей эффективности моделей использовались результаты работы на тесте COCO test-dev (Common Object in Context) [25]. Датасет COCO включает в себя более 300 000 реальных изображений, полученных в разных условиях, содержащих примерно 2 500 000 объектов 91 класса. Датасет рассчитан как для задач детекции объектов, так и для задач семантической сегментации и сегментации экземпляров, но в данном случае учитывались только результаты при детекции объектов.

МОРФОЛОГИЧЕСКИЙ АНАЛИЗ КОЛОНИЙ

Традиционно для классификации колоний используются следующие внешние морфологические признаки:

- размер: определяется в миллиметрах, как правило, от 1 до 5 мм;
- форма: может быть округлой, неправильной, мицеливидной, ризоидной, амебовидной, складчатой, концентрической, сложной и т. д.;
- поверхность: может быть гладкой, грубой, морщинистой и т. д.;
- цвет: некоторые микроорганизмы производят пигмент при росте;
- прозрачность: колонии могут быть прозрачными, полупрозрачными и непрозрачными;
- высота: описывает структуру высоты колонии, может быть приподнятой, полукруглой, сложной, кратеровидной и т. д.;
- края колонии: могут быть ровными, волнистыми и зубчатыми.

Помимо них, могут также применяться признаки запаха и консистенции колонии, но они не имеют критическое значение и их невозможно определить по изображению.

Согласно работе F. Yang, Y. Zhong, H. Yang и др. [4], при обучении моделей наблюдаются следующие зависимости:

- колонии малого размера с четкими краями легче поддаются обнаружению и показывают более высокую точность;
- крупные колонии с размытыми краями, как правило, определяются хуже;
- полупрозрачные и прозрачные колонии и колонии с высокой частотой пересечений между друг другом также показывают более низкую точность.

В работе S. Majchrowska, J. Pawlowski, N. Czerer и др. [23] отмечается, что колонии типа *P.aeruginosa* в среднем показывают низкую точность из-за большого количества пересечений. Также модель на основе архитектуры EfficientDet-D2 продемонстрировала тенденцию игнорировать колонии малого размера, в большинстве случаев не определяя ее рамки.

По результатам V. Shwetha, K. Prasad, C. Mukhopadhyay и др. [2], худшую точность показали *b.subtilis*, *p.aeruginosa* и *e.coli*. Это объясняется их нечеткими границами и плохим контрастом с фоном.

Данные результаты подчеркивают важность предобработки и нормализации входных данных (изображения), так как это позволяет увеличить контрастность изображения около колоний. Ручная регулировка контрастности также возможна, но может привести к повышению контрастности артефактов и увеличению количества ложноположительных результатов.

ФОРМАЛИЗАЦИЯ ЗАДАЧИ

Проблему обнаружения объектов определенных классов на изображении можно рассматривать либо в рамках семантической сегментации, либо как детекцию объектов [24].

Особенностью задачи семантической сегментации является то, что в ней отсутствует различие между объектами. Если 2 объекта одного класса пересекаются на изображении или находятся близко друг к другу, то даже в случае успешной работы модели сегментации найденные пиксели могут быть интерпретированы как один объект.

Семантическую сегментацию, в свою очередь, можно представить как попиксельную классификацию. Модель получает на вход изображение и выдает маску, которая указывает, к какому классу относится каждый отдельный пиксель.

При решении задачи детекции объектов модель также работает с изображением на входе, но на выходе возвращает произвольное число ограничивающих рамок обнаруженных объектов вместе с их классами. Исходя из этого, задача анализа изображений колоний микроорганизмов лучше интерпретируется как задача множественного детектирования объектов на изображении.

Пусть имеется изображение размером $W \times H$ пикселей, включающее в себя набор рамок P (1):

$$P = \{B_{i,j,k,l}\}, i = 1, \dots, W, j = 1, \dots, H, k = 1, \dots, W, l = 1, \dots, H, \quad (1)$$

где $B_{i,j,k,l}$ – ограничивающая рамка, описанная через координаты границ.

Цель состоит в определении множества рамок P' , соответствующих множеству колоний бактерий (2):

$$C = \{c_k\}_{k=1}^N, \quad (2)$$

где каждая колония c_k представлена координатами центра (x'_k, y'_k) и радиусом R_k .

Определим вероятность принадлежности рамки колонии:

$$P_{colony}(B_{i,j,k,l}, c_k) = \frac{\max(\min(x' + R, k) - \max(x' - R, i), 0) \cdot \max(\min(y' + R, l) - \max(y' - R, j), 0)}{(\max(k, x' + R) - \min(i, x' - R)) \cdot (\max(l, y' + R) - \min(j, y' - R))}. \quad (3)$$

Таким образом, задача заключается в минимизации целевой функции (4):

$$L_1 = \sum_{k=0}^N \left(\frac{1}{P_{colony}(B_k, c_k)} - 1 \right). \quad (4)$$

АРХИТЕКТУРЫ ДЛЯ РЕШЕНИЯ ЗАДАЧИ АНАЛИЗА ИЗОБРАЖЕНИЯ

Для решения задачи компьютерного зрения применяются глубокие нейронные сети – в частности, сверточные нейронные сети (англ. Convolutional Neural Network, далее CNN) и сети на основе архитектуры Трансформер (англ. Transformer).

В данной работе рассматриваются модели, обученные на датасете AGAR [7, 9, 10]. Для того чтобы рассмотреть также и модели, которые ранее не применялись в поставленной задаче, был рассмотрен ряд моделей, лидирующих по результатам тестов на COCO test-dev [14].

Наиболее распространены в задачах детекции объектов двухэтапные и одноэтапные CNN – сети [2]. В двухэтапном подходе на первом этапе генерируются предложения регионов (англ. Region Proposal), затем выделенные регионы масштабируются к единому размеру и из них извлекаются признаки, поступающие на вход классификатору. К ним относятся сети из семейства R-CNN. Одноэтапные архитектуры, как правило, показывают более высокую скорость работы, но, как правило, имеют меньшую точность [26]. К ним относятся такие архитектуры, как SSD и YOLO.

Модель ResNet-50 на протяжении долгого времени была наиболее распространенным решением для задач компьютерного зрения, так как стала одной из первых моделей глубокой нейронной сети и до сих пор показывает высокие результаты в ряде задач компьютерного зрения.

Типичным свойством сверточных нейронных сетей является то, что они сжимают исходное изображение на протяжении ряда внутренних слоев. Особенность HRNet (High Resolution Network) заключается в том, что извлеченные свойства параллельно обрабатываются как в исходном разрешении, так и в пониженном. В контексте поставленной задачи это свойство может положительно повлиять на результат, так как малый размер колоний может привести к полной потере информации о них [27].

Faster R-CNN – один из первых полностью сверточных двухэтапных детекторов, в котором региональные предложения генерируются не внешним алгоритмом, а специализированной сетью (Region Proposal Network, RPN). RPN совместно обучается с основной сетью, что позволяет генерировать ~300 предложений за один проход и сразу передавать их в RoI-пулинг для классификации и уточнения рамок [28].

RetinaNet – модель, где предложили «фокальную» (англ. Focal) функцию потерь, которая устраняет дисбаланс между фоном и объектами в одноэтапных сетях. Модификация функции ошибки заключается в том, что сложно классифицируемые примеры получают больший вес, а легко классифицируемые – меньший [29].

TOOD – модель, которая решает проблему рассогласования задач классификации и локализации в одноэтапных сетях через специальную «Task-Aligned Head». Она объединяет интерактивные и специализированные признаки для двух подзадач, а Task Alignment Learning (TAL) дополнительно выравнивает анкеры для обеих задач в процессе обучения [30].

YOLO вводит «единый» проход для предсказания классов и рамок прямоугольников, что позволило добиться очень высокой скорости. В модели изображение делится на сетку, и для каждой ячейки сеть сразу предсказывает несколько привязанных рамок и вероятности классов [31].

HRNet – модель, которая сохраняет потоки признаков высокого и пониженного разрешения на всем протяжении, многократно обмениваясь информацией между ними. Вместо «сжатия» к низкому разрешению и последующего «восстановления» HRNet сразу запускает несколько параллельных ветвей и объединяет их признаки на каждом блоке [32].

EfficientDet была разработана с целью оптимизации производительности за счет механизма взвешенных двунаправленных сетей характеристик (англ. Weighted Bi-directional Feature Pyramid Network) и метода составного масштабирования [36].

Особенностью архитектур Трансформер является применение механизма внимания. Входные данные делятся на сегменты, называемые эмбедингами, каждый сегмент включает в себя данные из окружающего контекста, после чего классификатор обрабатывает полученные эмбединги. Первоначально такие модели применялись в задачах обработки естественного языка, но с момента разработки архитектуры Vision Transformer (далее ViT) начали применяться в задачах анализа изображений [36]. В их контексте модель обрабатывает одинаково отмасштабированные части изображения как эмбединги.

К моделям на основе архитектуры Трансформер относятся такие архитектуры, как ViT, DETR (Detection Transformer), Swin (Shifted Window) и XCiT (Cross-Covariance Image Transformers).

Vision Transformer основан на идее обработки и классификации отдельных элементов изображения со включенным контекстом [21]. Модели такого типа, как правило, требуют большого объема свободной видеопамяти для работы на графическом чипе или видеокарте, но модель ViT, в частности, имеет вариацию Mobile ViT [16], ориентированную на работу на мобильных устройствах.

DETR был одной из первых архитектур, успешно применивших механизм самовнимания в контексте задачи компьютерного зрения. Некоторые ее новые вариации, такие как CO-DETR и Group DETR, показывают высокие результаты на тесте COCO и могут представлять интерес для поставленной задачи.

Идея архитектуры Swin заключается в разделении изображения на части еще более маленького размера (4x4 пикселя) и последующем слиянии их характеристик и понижении размерности для получения более высокоуровневого представления. В результате получается множество разноуровневых характеристик, отчасти схожих по структуре с CNN. Модели Swin лучше сохраняют детали изображений и показывают высокую точность на тесте COCO, но в силу их природы требуют большого объема памяти и лучше работают в виде основы для конечной сети [15].

Co-DETR вводит схему collaborative hybrid assignments, объединяя однократное и множество одновременных назначений меток для улучшения обучения энкодера и декодера без дорогостоящего NMS [13].

DINO (Swin L) (DETR with Improved Denoising Anchor Boxes) улучшает DETR через контрастное обучение для шумоподавления, метод смешанной выборки для инициализации якорей и двойной проход по предсказанным рамкам [12]. EVA – «чистая» вариация ViT с 1B параметров, разработанная с целью создания легко масштабируемого метода обработки изображений. Изначально обучена для воссоздания выделенных маской участков изображений, но применима, в том числе и для детекции объектов [11].

Swin V2-G является расширением Swin V2 до 3B параметров, поддерживает входные изображения до 1536×1536 [10].

BEiT-3 объединяет мономодальные и мультимодальные MIM-подходы для реализации многозадачной архитектуры, подходящей как для текстовых, так и графических входных данных [7].

Def. DETR решает две основные проблемы исходного DETR – медленную сходимость и ограниченное разрешение внимания – через выборку «деформируемых» точек вокруг опор. Вместо полного внимания по всему пространству каждая позиция «смотрит» на небольшое, обучаемое множество смещенных точек, что существенно снижает сложность и ускоряет обучение [33].

PvTv2 предлагает линейно масштабируемое ядро внимания, перекрывающиеся патч-эмбединги

и сверточный FFN для экономии ресурсов. Модель сохраняет пирамиду признаков по разрешению, адаптируя патч-эмбединг с перекрытиями и снижая сложность внимания до линейной [34].

PLG-ViT сочетает локальное оконное самовнимание с глобальным самовнением, обеспечивая богатый контекст на разных масштабах. У модели две ветви – одна – ограниченного локального окна, другая – глобальная, – параллельно извлекают признаки, после чего их объединяют [35].

МЕТРИКИ КАЧЕСТВА МОДЕЛЕЙ

Все используемые в машинном обучении метрики так или иначе рассчитываются из количества полученных истинных и ложных положительных/отрицательных результатов – True Positive (далее TP), True Negative (далее TN), False Positive (далее FP) и False Negative (далее FN).

Наиболее распространенными метриками для задач машинного обучения являются метрики Precision, Accuracy и Recall.

Accuracy рассчитывается как отношение верно определенных результатов к общему количеству результатов. Эта метрика не подходит для большинства задач, особенно для задач с неравномерным распределением по классам так как ее результат может улучшаться в случае, если модель игнорирует наименее распространенный класс.

Precision выражает долю корректных положительных результатов от всех возвращенных положительных результатов.

Recall выражает долю корректных положительных результатов от всех ожидаемых положительных результатов.

Использование лишь метрики Precision или Recall может привести к тому, что значение другой метрики будет падать.

В задачах детекции объектов для решения этой проблемы используется величина средней точности mAP (англ. Mean Average Precision) (5) [22]:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i. \tag{5}$$

AP (англ. Average Precision) – величина средней точности по классу, определяющаяся как площадь под кривой Precision-Recall (6):

$$AP = \sum_{k=1}^n Precision(k) \cdot \Delta Recall(k). \tag{6}$$

Для оценки совпадения рамок применяется величина IoU (7):

$$IoU = \frac{B_1 \cap B_2}{B_1 \cup B_2}, \tag{7}$$

где B_1 – площадь ожидаемой ограничивающей рамки;

B_2 – площадь найденной ограничивающей рамки.

СРАВНИТЕЛЬНАЯ ТАБЛИЦА МОДЕЛЕЙ

В таблице 1 приведены характерные метрики mAP для ключевых моделей на наборе данных AGAR [6, 8, 9].

Таблица 1 – Сравнение результатов моделей, обученных на датасете AGAR

Модель	mAP, %
ResNet-50	56,0
HRNet	59,4
Faster R-CNN	56,0
RetinaNet	59,2
TOOD	66,9
Def. DETR	66,4
PvTv2	55,8
PLG-ViT	56,1

По полученным данным видно, что архитектуры TOOD и Def. DETR показали лучшую точность. В таблице 2 приведены характерные метрики mAP для ключевых моделей на тесте COCO test-dev.

Таблица 2 – Сравнение результатов моделей, обученных на тесте COCO test-dev

Модель	Количество параметров	mAp, %
Co-DETR	304M	66,0
DINO (Swin L)	218M	63,3
EVA	1B	64,7
Swin V2-G	3B	64,2
Plain DETR (Swin L)	228M	63,9
BEiT-3	1.9B	63,7
ViT-Adapter-L	347.9M	60,9
YOLOv7-D6	154.7M	56,6
EfficientDet-D7	52M	52,6
RetinaNet	163,6M	52,1

По полученным данным видно, что архитектуры-трансформеры, такие как Co-DETR, EVA, DINO и Swin, показали лучшую точность на датасете общего типа. Чистый ViT, адаптированный под эту задачу, занимает нишу между State-Of-The-Art сетями и CNN-сетями, оптимизированными под больший спектр устройств – такими как YOLO и EfficientNet.

ОБСУЖДЕНИЕ

Наивысшую точность показывают модели на базе архитектуры Трансформер. Лидером в задаче детекции объектов является Co-DETR. Многие из state-of-the-art архитектур, хотя и показывают высокую точность, предъявляют высокие системные требования. Например, архитектуры EVA и Swin были разработаны с целью создания легко масштабируемой архитектуры, и указанная точность была достигнута при использовании 1 000 000 000 и 3 000 000 000 обучаемых параметров соответственно. Модель Deformable DETR, согласно документации [5], требует, в зависимости от версии, от 15 Гб видеопамати для обучения. При реальной работе на графическом чипе или видеокарте они требовали бы более 3 Гб и 10 Гб свободной видеопамати, что в случае множества реальных исследований является нереалистичным условием.

Современные одноэтапные детекторы, такие как YOLO, демонстрируют точность, незначительно уступающую лидирующим моделям. Это делает их особенно перспективными для приложений, обрабатывающих изображения в реальном времени, или для мобильных устройств. Их простота развертывания и гибкость позволяют адаптироваться к различным условиям съёмки и применять в полевых условиях, но результат их работы будет требовать как минимум поверхностную ручную проверку.

Модели, основанные на трансформерах (Swin, DETR), превосходят CNN в устойчивости к изменениям фона, освещения и структуры колоний благодаря вниманию к глобальному контексту. Особенно это заметно при слиянии колоний или их неполной сегментации.

Ряд моделей показал индивидуальные особенности в ходе работы. В статье N. Ebert, D. Stricker и O. Wasenmuller [9] отмечается, что модель PVTv2 требует вычислительные мощности выше аналогов, таких как Swin и PLG-ViT, занимает больше времени для обработки одного изображения и требует на 200 % больше видеопамати и ее предполагается использовать как основу для конечной модели. Согласно результатам S. Majchrowska, J. Pawlowski, N. Czerep и др. [23], модель на основе архитектуры EfficientDet-D2 продемонстрировала тенденцию игнорировать колонии малого размера, не определяя их рамки.

Модели показывают снижение точности в случаях:

- сильно размытых краёв колоний;
- плотного скопления мелких колоний (слияние);
- низкого контраста между средой и колониями;
- атипичных форм (зигзагообразные, лопастные края).

Наиболее перспективным направлением дальнейшего исследования является применение легковесных версий state-of-the-art архитектур, в частности легких версий DETR, Swin и Vision Transformer, включая Mobile Vision Transformer. Предполагается, что с их помощью получится избежать свойства CNN-архитектур игнорировать колонии меньшего размера и контраста, сохранив допустимые требования к устройству, на котором работает модель. Вместе с этим большинство моделей показывают время обработки одного изображения до 1 секунды, редко пересекая порог в 100 мс при работе на GPU, чего достаточно для поставленной задачи.

ЗАКЛЮЧЕНИЕ

В ходе исследования подтверждена высокая эффективность глубоких моделей для анализа изображений бактериальных колоний. Архитектуры на базе трансформеров (Co-DETR, Deformable DETR, Swin-Transformer и др.) показали наивысшую точность детекции, однако их применение в практических задачах ограничено значительными вычислительными требованиями: для обучения и инференса некоторых моделей (например, EVA, Swin) требуются сотни миллионов и миллиарды параметров и десятки гигабайт видеопамати. Deformable DETR в зависимости от конфигурации предъявляет потребность в 15 ГБ видеопамати, что выходит за рамки доступных ресурсов во многих лабораториях.

Одноэтапные детекторы семейства YOLO демонстрируют точность, лишь незначительно уступающую лидерам, но при этом обладают существенно меньшими системными требованиями и скоростью инференса в десятки-сотни кадров в секунду. Их простота развертывания и возможность работы в реальном времени делают их оптимальным выбором для полевых приложений и мобильных устройств, хотя в ряде случаев требуется проверка результатов оператором.

Модели на базе трансформеров превосходят классические CNN не только в точности, но и в устойчивости к изменениям фона, освещения и плотности колоний за счет внимания к глобальным паттернам. Тем не менее некоторые варианты, например PVTv2, требуют еще больше ресурсов по сравнению с аналогичными Swin- или PLG-ViT-архитектурами, а EfficientDet-D2 демонстрирует склонность игнорировать мелкие объекты.

Наиболее перспективным направлением представляется разработка легких версий трансформеров (Mobile ViT, lightweight DETR, Swin-T), которые сохраняют способность обнаруживать колонии небольшого размера и низкого контраста, одновременно укладываясь в ограниченные аппаратные ресурсы. Такие модели позволят обеспечить время обработки одного изображения на уровне сотен миллисекунд при сохранении высокой точности, что критично для задач клинической диагностики, санитарного контроля и образовательных лабораторий.

Список источников

- Galope, R. M. R. Automated Bacteria Colony Counting using Hybrid Image Segmentation Algorithm and YOLOv5 Transfer Learning Model / R. M. R. Galope, C. B. Lisondra, A. C. J. J. Nanaul. – 37 P. – URL: <https://www.ijirmp.org/special-issues/4/206.pdf> (дата обращения: 19.05.2025).
- Shwetha, V. Vision transformer based bacteria classification model for Gram-stained direct smear images / V. Shwetha, K. Prasad, C. Mukhopadhyay [et al.]. – 21 p. – URL: <https://link.springer.com/article/10.1007/s11042-025-20742-0> (дата обращения: 19.05.2025).
- Santiago, J. U. Vision Transformers for Weakly-Supervised Microorganism Enumeration / J. U. Santiago, T. Strohle, A. Rodriguez-Sanchez [et al.]. – 8 p. – URL: <https://arxiv.org/abs/2412.02250> (дата обращения: 19.05.2025).
- Yang, F. Microbial Colony Detection Based on Deep Learning / F. Yang, Y. Zhong, H. Yang [et al.]. – 16 P. – URL: https://www.researchgate.net/publication/374131339_Microbial_Colony_Detection_Based_on_Deep_Learning (дата обращения: 19.05.2025).
- NVIDIA. Deformable DETR // NVIDIA Developer Documentation. – URL: https://docs.nvidia.com/tao/archive/5.3.0/text/object_detection/deformable_detr.html (дата обращения: 19.05.2025).
- Majchrowska, S. AGAR: a microbial colony dataset for deep learning detection / S. Majchrowska, J. Pawlowski, G. Gula [et al.]. – 26 p. – URL: <https://arxiv.org/abs/2108.01234> (дата обращения: 19.05.2025).
- Wang, W. Image as a Foreign Language: BEiT Pretraining for All Vision and Vision-Language Tasks / W. Wang, H. Bao, L. Dong [et al.]. – 18 p. – URL: <https://arxiv.org/abs/2208.10442> (дата обращения: 19.05.2025).
- Ebert, N. Light-Weight Vision Transformer with Parallel Local and Global Self-Attention / N. Ebert, L. Reichardt, D. Stricker [et al.]. – 8 p. – URL: <https://arxiv.org/abs/2307.09120> (дата обращения: 19.05.2025).
- Ebert, N. Transformer-based Detection of Microorganisms on High-Resolution Petri Dish Images / N. Ebert, D. Stricker, O. Wasenmuller. – 10 p. – URL: <https://arxiv.org/abs/2308.09436> (дата обращения: 21.05.2025).
- Swin Transformer V2: Scaling Up Capacity and Resolution / Z. Liu, H. Hu, Y. Lin [et al.]. – 15 p. – URL: <https://arxiv.org/abs/2111.09883> (дата обращения: 19.05.2025).
- Fang, Y. Exploring the Limits of Masked Visual Representation Learning at Scale / Y. Fang, W. Wang, B. Xie [et al.]. – 15 p. – URL: <https://arxiv.org/abs/2211.07636> (дата обращения: 19.05.2025).
- DINO: DETR with Improved DeNoising Anchor Boxes for End-to-End Object Detection / H. Zhang, F. Li, S. Liu [et al.]. – 23 p. – URL: <https://arxiv.org/abs/2203.03605> (дата обращения: 19.05.2025).
- Zong, Z. DETRs with Collaborative Hybrid Assignments Training / Z. Zong, G. Song, Y. Liu. – 13 P. – URL: <https://arxiv.org/abs/2211.12860> (дата обращения: 20.05.2025).
- Object Detection on COCO test-dev // Веб-сервис Papers with Code. – URL: <https://paperswithcode.com/sota/object-detection-on-coco> (дата обращения: 19.05.2025).

15. Liu, Z. Swin Transformer: Hierarchical Vision Transformer using Shifted Windows / Z. Liu, Y. Lin, Y. Cao [et al.]. – 14 p. – URL: <https://arxiv.org/abs/2103.14030> (дата обращения: 20.05.2025).
16. Mehta S. MobileViT: Light-weight, General-purpose, and Mobile-friendly Vision Transformer / S. Mehta, M. Rastegari. – 26 p. – URL: <https://arxiv.org/abs/2110.02178> (дата обращения: 20.05.2025).
17. Investigating Microbial (Micro)colony Heterogeneity by Vibrational Spectroscopy / L.-P. Choo-Smith, K. Maquelin, T. van Vreeswijk [et al.]. – 9 p. – URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC92755> (дата обращения: 20.05.2025).
18. Watrous, J. Mass spectral molecular networking of living microbial colonies / J. Watrous, P. Roach, T. Alexandrov [et al.]. – 10 p. – URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC3387089> (дата обращения: 20.05.2025).
19. An Automated Bacterial Colony Counting System / C. Zhang, W.-B. Chen, W.-L. Liu [et al.] – 8 p. – URL: <https://cpb-us-w2.wpmucdn.com/sites.uab.edu/dist/3/66/files/2020/01/SNUTS2008.pdf> (дата обращения: 20.05.2025).
20. Brugger, S. D. Automated Counting of Bacterial Colony Forming Units on Agar Plates / S. D. Brugger, C. Baumberger, M. Jost [et al.]. – 6 p. – URL: https://www.researchgate.net/publication/221976954_Automated_Counting_of_Bacterial_Colony_Forming_Units_on_Agar_Plates (дата обращения: 20.05.2025).
21. Dosovitskiy, A. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale / A. Dosovitskiy, L. Beyer, A. Kolesnikov [et al.]. – 22 p. – URL: <https://arxiv.org/abs/2010.11929> (дата обращения: 20.05.2025).
22. Wang, B. A Parallel Implementation of Computing Mean Average Precision / B. Wang. – 15 p. – URL: <https://arxiv.org/abs/2206.09504> (дата обращения: 20.05.2025).
23. Deep Neural Networks Approach to Microbial Colony Detection – A Comparative Analysis / S. Majchrowska, J. Pawlowski, N. Czerep [et al.]. – 9 p. – URL: <https://arxiv.org/abs/2108.10103v2> (дата обращения: 20.05.2025).
24. Xie, C. Adversarial Examples for Semantic Segmentation and Object Detection / C. Xie, J. Wang, Z. Zhang [et al.]. – 12 p. – URL: <https://arxiv.org/abs/1703.08603> (дата обращения: 20.05.2025).
25. Lin, T.-Y. Microsoft COCO: Common Objects in Context / T.-Y. Lin, M. Maire, S. Belongie [et al.]. – 15 p. – URL: <https://arxiv.org/abs/1405.0312> (дата обращения: 20.05.2025).
26. Agarwal, S. Recent Advances in Object Detection in the Age of Deep Convolutional Neural Networks / S. Agarwal, J. Ogier Du Terrail, F. Jurie. – 104 p. – URL: <https://arxiv.org/abs/1809.03193> (дата обращения: 20.05.2025).
27. Li, S. A Small Object Detection Algorithm for Traffic Signs Based on Improved YOLOv7 / S. Li, S. Wang, P. Wang. – 22 p. – URL: https://www.researchgate.net/publication/373122626_A_Small_Object_Detection_Algorithm_for_Traffic_Signs_Based_on_Improved_YOLOv7 (дата обращения: 20.05.2025).
28. Ren, S. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks / S. Ren, K. He, R. Girshick [et al.]. – 14 p. – URL: <https://arxiv.org/abs/1506.01497> (дата обращения: 20.05.2025).
29. Lin, T.-Y. Focal Loss for Dense Object Detection / T.-Y. Lin, P. Goyal, R. Girshick [et al.]. – 10 p. – URL: <https://arxiv.org/abs/1708.02002> (дата обращения: 20.05.2025).
30. Feng, C. TOOD: Task-aligned One-stage Object Detection / C. Feng, Y. Zhong, Y. Gao [et al.]. – 12 p. – URL: <https://arxiv.org/abs/2108.07755> (дата обращения: 20.05.2025).
31. Wang, C.-Y. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors / C.-Y. Wang, A. Bochkovskiy, H.-Y. Mark Liao. – 15 p. – URL: <https://arxiv.org/abs/2207.02696> (дата обращения: 20.05.2025).
32. Wang, J. Deep High-Resolution Representation Learning for Visual Recognition / J. Wang, K. Sun, T. Cheng [et al.]. – 23 P. – URL: <https://arxiv.org/abs/1908.07919> (дата обращения: 20.05.2025).
33. Zhu, X. Deformable DETR: Deformable Transformers for End-to-End Object Detection / X. Zhu, W. Su, L. Lu [et al.]. – 16 P. – URL: <https://arxiv.org/abs/2010.04159> (дата обращения: 20.05.2025).
34. Wang, W. PVT v2: Improved Baselines with Pyramid Vision Transformer / W. Wang, E. Xie, X. Li [et al.]. – 8 p. – URL: <https://arxiv.org/abs/2106.13797> (дата обращения: 20.05.2025).
35. Ebert, N. Light-Weight Vision Transformer with Parallel Local and Global Self-Attention / N. Ebert, L. Reichardt, D. Stricker [et al.]. – 8 p. – URL: <https://arxiv.org/abs/2307.09120> (дата обращения: 20.05.2025).
36. Tan, M. EfficientDet: Scalable and Efficient Object Detection / M. Tan, R. Pang, Q.V. Le. – 10 p. – URL: <https://arxiv.org/abs/1911.09070> (дата обращения: 20.05.2025).

References

1. Galope, R. M. R., Lisondra, C. B., Nuanal, A. C. J. J. *Automated Bacteria Colony Counting using Hybrid Image Segmentation Algorithm and YOLOv5 Transfer Learning Model*. 37 p. Available at: <https://www.ijrmpms.org/special-issues/4/206.pdf> (accessed 19.05.2025).
2. Shwetha, V., Prasad, K., Mukhopadhyay, C. [et al.]. *Vision transformer based bacteria classification model for Gram-stained direct smear images*. 21 p. Available at: <https://link.springer.com/article/10.1007/s11042-025-20742-0> (accessed 19.05.2025).
3. Santiago, J. U., Strohle, T., Rodriguez-Sanchez, A. [et al.]. *Vision Transformers for Weakly-Supervised Microorganism Enumeration*. 8 p. Available at: <https://arxiv.org/abs/2412.02250> (accessed 19.05.2025).
4. Yang, F., Zhong, Y., Yang, H. [et al.]. *Microbial Colony Detection Based on Deep Learning*. 16 p. Available at: https://www.researchgate.net/publication/374131339_Microbial_Colony_Detection_Based_on_Deep_Learning (accessed 19.05.2025).
5. NVIDIA. Deformable DETR. *NVIDIA Developer Documentation*. Available at: https://docs.nvidia.com/tao/archive/5.3.0/text/object_detection/deformable_detr.html (accessed 19.05.2025).
6. Majchrowska, S., Pawlowski, J., Gula, G. [et al.]. *AGAR: a microbial colony dataset for deep learning detection*. 26 p. Available at: <https://arxiv.org/abs/2108.01234> (accessed 19.05.2025).
7. Wang, W., Bao, H., Dong, L. [et al.]. *Image as a Foreign Language: BEiT Pretraining for All Vision and Vision-Language Tasks*. 18 p. Available at: <https://arxiv.org/abs/2208.10442> (accessed 19.05.2025).

8. Ebert, N., Reichardt, L., Stricker, D. [et al.]. Light-Weight Vision Transformer with Parallel Local and Global Self-Attention. 8 p. Available at: <https://arxiv.org/abs/2307.09120> (accessed 19.05.2025).
9. Ebert N., Stricker, D., Wasenmuller, O. *Transformer-based Detection of Microorganisms on High-Resolution Petri Dish Images*. 10 p. Available at: <https://arxiv.org/abs/2308.09436> (accessed 21.05.2025).
10. Liu, Z., Hu, H., Lin, Y. [et al.]. *Swin Transformer V2: Scaling Up Capacity and Resolution*. 15 p. Available at: <https://arxiv.org/abs/2111.09883> (accessed 19.05.2025).
11. Fang, Y., Wang, W., Xie, B. [et al.]. *Exploring the Limits of Masked Visual Representation Learning at Scale*. 15 p. Available at: <https://arxiv.org/abs/2211.07636> (accessed 19.05.2025).
12. Zhang, H., Li, F., Liu, S. [et al.]. *DINO: DETR with Improved DeNoising Anchor Boxes for End-to-End Object Detection*. 23 p. Available at: <https://arxiv.org/abs/2203.03605> (accessed: 19.05.2025).
13. Zong, Z., Song, G., Liu, Y. *DETRs with Collaborative Hybrid Assignments Training*. 13 p. Available at: <https://arxiv.org/abs/2211.12860> (accessed 20.05.2025).
14. Object Detection on COCO test-dev. *Веб-сервис Papers with Code*. Available at: <https://paperswith-code.com/sota/object-detection-on-coco> (accessed 19.05.2025).
15. Liu, Z., Lin, Y., Cao, Y. [et al.]. *Swin Transformer: Hierarchical Vision Transformer using Shifted Windows*. 14 p. Available at: <https://arxiv.org/abs/2103.14030> (accessed 20.05.2025).
16. Mehta, S., Rastegari, M. *MobileViT: Light-weight, General-purpose, and Mobile-friendly Vision Transformer*. 26 p. Available at: <https://arxiv.org/abs/2110.02178> (accessed 20.05.2025).
17. Choo-Smith, L.-P., Maquelin K., Vreeswijk, T. van [et al.]. *Investigating Microbial (Micro)colony Heterogeneity by Vibrational Spectroscopy*. 9 p. Available at: <https://pmc.ncbi.nlm.nih.gov/articles/PMC92755> (accessed 20.05.2025).
18. Watrous, J., Roach, P., Alexandrov, T. [et al.]. *Mass spectral molecular networking of living microbial colonies*. 10 p. Available at: <https://pmc.ncbi.nlm.nih.gov/articles/PMC3387089> (accessed 20.05.2025).
19. Zhang, C., Chen, W.-B., Liu, W.-L. [et al.]. *An Automated Bacterial Colony Counting System*. 8 p. Available at: <https://cpb-us-w2.wpmucdn.com/sites.uab.edu/dist/3/66/files/2020/01/SNUTS2008.pdf> (accessed 20.05.2025).
20. Brugger, S. D., Baumberger, C., Jost, M. [et al.]. Automated Counting of Bacterial Colony Forming Units on Agar Plates. 6 p. Available at: https://www.researchgate.net/publication/221976954_Automated_Counting_of_Bacterial_Colony_Forming_Units_on_Agar_Plates (accessed 20.05.2025).
21. Dosovitskiy, A., Beyler, L., Kolesnikov, A. [et al.]. *An Image is Worth 16×16 Words: Transformers for Image Recognition at Scale*. 22 p. Available at: <https://arxiv.org/abs/2010.11929> (accessed 20.05.2025).
22. Wang, B. *A Parallel Implementation of Computing Mean Average Precision*. 15 p. Available at: <https://arxiv.org/abs/2206.09504> (accessed 20.05.2025).
23. Majchrowska, S., Pawlowski, J., Czerep, N. [et al.]. *Deep Neural Networks Approach to Microbial Colony Detection – A Comparative Analysis*. 9 p. Available at: <https://arxiv.org/abs/2108.10103v2> (accessed 20.05.2025).
24. Xie, C., Wang, J., Zhang, Z. [et al.]. *Adversarial Examples for Semantic Segmentation and Object Detection*. 12 p. Available at: <https://arxiv.org/abs/1703.08603> (accessed 20.05.2025).
25. Lin, T.-Y., Maire, M., Belongie, S. [et al.]. *Microsoft COCO: Common Objects in Context*. 15 p. Available at: <https://arxiv.org/abs/1405.0312> (accessed 20.05.2025).
26. Agarwal, S., J. Ogier Du Terrail, Jurie, F. Recent Advances in Object Detection in the Age of Deep Convolutional Neural Networks. 104 p. Available at: <https://arxiv.org/abs/1809.03193> (accessed 20.05.2025).
27. Li S., Wang, S., Wang, P. *A Small Object Detection Algorithm for Traffic Signs Based on Improved YOLOv7*. 22 p. Available at: https://www.researchgate.net/publication/373122626_A_Small_Object_Detection_Algorithm_for_Traffic_Signs_Based_on_Improved_YOLOv7 (accessed 20.05.2025).
28. Ren, S., He, K., Girshick, R. [et al.]. *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. 14 p. Available at: <https://arxiv.org/abs/1506.01497> (accessed 20.05.2025).
29. Lin, T.-Y., Goyal, P., Girshick, R. [et al.]. *Focal Loss for Dense Object Detection*. 10 p. Available at: <https://arxiv.org/abs/1708.02002> (accessed 20.05.2025).
30. Feng, C., Zhong, Y., Gao, Y. [et al.]. *TOOD: Task-aligned One-stage Object Detection*. 12 p. Available at: <https://arxiv.org/abs/2108.07755> (accessed 20.05.2025).
31. Wang, C.-Y., Bochkovskiy, A., Mark Liao, H.-Y. *YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors*. 15 p. Available at: <https://arxiv.org/abs/2207.02696> (accessed 20.05.2025).
32. J. Wang, K. Sun, T. Cheng [et al.]. *Deep High-Resolution Representation Learning for Visual Recognition*. 23 p. Available at: <https://arxiv.org/abs/1908.07919> (accessed 20.05.2025).
33. Zhu, X., Su, W., Lu, L. [et al.]. *Deformable DETR: Deformable Transformers for End-to-End Object Detection*. 16 p. Available at: <https://arxiv.org/abs/2010.04159> (accessed 20.05.2025).
34. Wang, W., Xie, E., Li, X. [et al.]. *PVT v2: Improved Baselines with Pyramid Vision Transformer*. 8 p. Available at: <https://arxiv.org/abs/2106.13797> (accessed 20.05.2025).
35. Ebert, N., Reichardt, L., Stricker, D. [et al.]. *Light-Weight Vision Transformer with Parallel Local and Global Self-Attention*. 8 p. Available at: <https://arxiv.org/abs/2307.09120> (accessed 20.05.2025).
36. Tan M., Pang, R., Le, Q. V. *EfficientDet: Scalable and Efficient Object Detection*. 10 p. Available at: <https://arxiv.org/abs/1911.09070> (accessed 20.05.2025).

Статья поступила в редакцию 30.05.2025; одобрена после рецензирования 15.07.2025; принята к публикации 31.07.2025.

The article was submitted 30.05.2025; approved after reviewing 15.07.2025; accepted for publication 31.07.2025.

УДК 004.8

**ФОРМИРОВАНИЕ ОБУЧАЮЩЕГО МНОЖЕСТВА НА ОСНОВЕ ДАННЫХ
ДОЛЖНИКОВ, ХРАНИМЫХ КОЛЛЕКТОРСКИМ АГЕНТСТВОМ**

Демина Раиса Юрьевна, Астраханский государственный технический университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 16/1, кандидат технических наук, доцент, ORCID: 0009-0009-1615-5641, e-mail: raisa.demina.91@mail.ru

Ашимов Микаэл Мусаевич, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, магистрант, ORCID: 0000-0002-9505-3038, e-mail: ammichl88@gmail.com

Лепехин Денис Алексеевич, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, магистрант, ORCID: 0000-0003-2499-847X, e-mail: lepehin_denis@mail.ru

Есауленко Владимир Николаевич, Астраханский государственный технический университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 16/1, доктор технических наук, профессор, ORCID: 0009-0003-2462-5232, e-mail: atp@astu.org

Данная статья представляет собой обзор особенностей создания обучающего множества на основе информации, хранящейся в коллекторских агентствах. Коллекторские агентства занимаются взысканием задолженностей у должников, их работа включает в себя сбор информации о должниках, взаимодействие с ними, анализ данных и принятие решений. Создание обучающего множества на основе информации из коллекторских агентств представляет собой сложный и многоэтапный процесс, который требует проведения ряда преобразований и анализа данных. Первым делом данные нужно преобразовать к единому формату, чтобы обеспечить их сопоставимость и возможность дальнейшего анализа. После этого проводится корреляционный анализ данных, который позволяет выявить взаимосвязи между различными переменными в обучающем множестве. Нормализация данных также является важным этапом, поскольку она позволяет привести данные к стандартному виду и устранить искажения, вызванные различными единицами измерения или масштабами. Также важным моментом является поиск взаимосвязей между различными переменными, что позволяет выявить скрытые закономерности и тренды в данных. По итогам работы был проведен анализ данных по перечисленным методам.

Ключевые слова: обучающее множество, данные должников, коллекторское агентство, формирование выборки, анализ задолженностей, кредитоспособность, методы отбора, прогностическое моделирование

**FORMATION OF A TRAINING SET BASED ON DEBTORS' DATA
STORED BY A COLLECTION AGENCY**

Demina Raisa Y., Astrakhan State Technical University, 16/1 Tatishchev St., Astrakhan, 414056, Russian Federation,

Cand. Sci. (Engineering), Associate Professor, ORCID: 0009-0009-1615-5641, e-mail: raisa.demina.91@mail.ru

Ashimov Mikael M., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

MA student, ORCID: 0000-0002-9505-3038, e-mail: ammichl88@gmail.com

Lepekhin Denis A., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

MA student, ORCID: 0000-0003-2499-847X, e-mail: lepehin_denis@mail.ru

Esaulevko Vladimir N., Astrakhan State Technical University, 16/1 Tatishchev St., Astrakhan, 414056, Russian Federation.

Doct. Sci. (Engineering), Professor, ORCID: 0009-0003-2462-5232, e-mail: atp@astu.org

This article provides an overview of the features of creating a training set based on information stored in collection agencies. Collection agencies collect debts from debtors, and their work includes collecting information about debtors, interacting with them, analyzing data, and making decisions. Creating a training set based on information from collection agencies is a complex and multi-step process that requires several transformations and data analysis. First, the data needs to be converted to a single format to ensure their comparability and the possibility of further analysis. After that, a correlation analysis of the data is performed, which allows us to identify the relationships between various variables in the training set. Normalization of data is also an important step, as it allows you to bring data to a standard form and eliminate distortions caused by different units of measurement or scales. Also, an important point is to search for relationships between different variables, which allows you to identify hidden patterns and trends in the data. Based on the results of the work, an analysis of the data on the listed methods was carried out.

Keywords: training set, debtor data, collection agency, sampling, debt analysis, creditworthiness, selection methods, predictive modeling

ВВЕДЕНИЕ

В современном мире, где экономика и бизнес постоянно развиваются, одной из актуальных проблем является взыскание задолженностей. Задолженности могут возникать по различным причинам: от неисполнения обязательств по контрактам до неоплаты коммунальных услуг. Эффективное взыскание задолженностей играет важную роль в обеспечении стабильности финансовой системы, а также в поддержании экономической активности на должном уровне. Одним из перспективных направлений в данной области является применение искусственного интеллекта (ИИ) для прогнозирования взыскания задолженностей. Использование ИИ позволяет автоматизировать процесс анализа данных, выявления закономерностей и принятия решений, что может существенно повысить эффективность взыскания задолженностей и снизить затраты на его осуществление. Однако для применений технологий ИИ необходимо логически правильно подготовить данные о должниках, собрать их в обучающее множество. Ведь использование различных моделей ИИ во многом зависит и от входных данных.

ОПИСАНИЕ ДАННЫХ

Процессом взыскания долгов занимаются специализированные организации, называемые коллекторскими агентствами (КА).

Коллекторские агентства в Российской Федерации – это специализированные организации, занимающиеся взысканием задолженностей от должников от имени и по поручению кредиторов. Они могут работать как независимые структуры, так и быть частью кредитных организаций или других финансовых учреждений. Деятельность коллекторских агентств регулируется законодательством Российской Федерации, включая № 230-ФЗ [1].

Коллекторское агентство обрабатывает большие объемы данных, что связано со спецификой процесса получения информации о должниках, которая заключается в работе с различными финансовыми организациями. Эта информация предоставляет возможность формировать уникальные обучающие множества, которые могут быть использованы для обучения и развития моделей ИИ. Однако эти данные необходимо правильно преобразовать и определить взаимосвязи между ними.

Коллекторские агентства обладают достаточным количеством информации о должниках для эффективного взыскания задолженностей. Эта информация содержит:

- 1) пол должника;
- 2) дата рождения;
- 3) место рождения;
- 4) место проживания;
- 5) сумма задолженности;
- 6) сумма платежей по задолженности;
- 7) срок просрочки;
- 8) сумма процентов по долгу;
- 9) дата планового погашения;
- 10) информация по кредиту.

Также по ходу работы КА собирает и хранит информацию о результатах сбора задолженностей. Такая информация может содержать:

- 1) статистику по телефонным разговорам;
- 2) статистику по отправкам бумажных писем;
- 3) статистику по отправкам электронных писем (e-mail).

Вся эта информация содержится в базе данных КА, поэтому перед формированием обучающего множества нужно собрать их в единую таблицу.

ПРИВЕДЕНИЕ ДАННЫХ К ЕДИНОМУ ФОРМАТУ

Данные могут иметь разный формат представления: число, дата, текст. Для использования их в моделях ИИ необходимо логически преобразовать все данные в числовые.

К примеру, пол должника можно представить в виде 0 и 1. Это может выглядеть следующим образом (табл. 1).

Таблица 1 – преобразование пола должника в числовые значения

М/Ж	М	Ж
М	1	0
Ж	0	1

Содержащиеся данные об адресах должников также нужно привести к числовым значениям, например, используя код региона, численность населения. Таким образом необходимо преобразовать все данные в обучающем множестве.

Данные в формате дат также нужно привести к числовым значениям по средствам преобразования их в количество дней до текущей или конкретной даты, в зависимости от задачи. Этот подход позволяет лучше оценить временные параметры и сделать данные более «податливыми» к различным аналитическим методам.

НОРМАЛИЗАЦИЯ ДАННЫХ

После преобразования данных в числовой формат необходимо их проанализировать для дальнейшего использования. В обучающем множестве могут получиться сильно различающиеся по размерности значения. Например, один параметр может измеряться в диапазоне от 0 до 1, к примеру, полдолжника, преобразованный в числа, другой – в сотнях тысяч. В таком случае их нужно нормализовать.

Нормализация данных – это приведение различных данные в самых разных единицах измерения и диапазонах значений к единому виду, который позволит сравнивать их между собой или использовать для расчета схожести объектов [2].

Методики нормализации используются для приведения данных к определенному диапазону значений, чтобы облегчить их обработку и анализ [3–6]. Некоторые из наиболее распространенных методик нормализации включают в себя:

1. Мини-макс нормализация: метод нормализует данные путем преобразования каждого значения в диапазон от 0 до 1. Формула для мини-макс нормализации выглядит следующим образом:

$$((x - \min)) / ((\max - \min)), \quad (1)$$

где x – исходное значение;

\min – минимальное значение в наборе данных;

\max – максимальное значение.

2. Z-нормализация: метод используется для нормализации данных путем вычитания среднего значения и деления на стандартное отклонение. Формула z-нормализации выглядит следующим образом:

$$((x - \mu)) / \sigma, \quad (2)$$

где x – исходное значение;

μ – среднее значение в наборе данных;

σ – стандартное отклонение.

3. Стандартизация: метод нормализации, который заключается в преобразовании данных таким образом, что они имеют среднее значение 0 и стандартное отклонение 1. Формула стандартизации выглядит следующим образом:

$$((x - u)) / s, \quad (3)$$

где x – исходное значение;

u – среднее значение;

s – стандартное отклонение в наборе данных.

Была выбрана Z-нормализация, так как у нее лучшая совместимость с алгоритмами машинного обучения, а также за счет использования среднего и стандартного отклонений, она устойчива к выбросам.

КОРРЕЛЯЦИЯ ДАННЫХ

После приведения данных к одному виду важно определить и взаимосвязи между ними. Одним из способов количественной оценки этой взаимосвязи является использование коэффициента корреляции Пирсона – меры линейной связи между двумя переменными [7].

Он имеет значение от -1 до 1 , где:

– -1 указывает на совершенно отрицательную линейную корреляцию между двумя переменными;

– 0 указывает на отсутствие линейной корреляции между двумя переменными;

– 1 указывает на совершенно положительную линейную корреляцию между двумя переменными.

Для удобного анализа корреляций можно использовать матрицу корреляций – статистический инструмент, используемый для измерения степени линейной связи (корреляции) между двумя переменными. Он показывает, как изменение одной переменной влияет на изменение другой переменной.

Таблица 2 – Набор признаков для расчёта корреляций

Название	Что показывает	Тип данных
DaysFromBorn	Количество дней с момента рождения	int
Male	Признак мужского пола (1 – мужчина, 0 – не мужчина)	bool
Female	Признак женского пола (1 – женщина, 0 – не женщина)	bool
DateStartCredit	Дата начала кредита	datetime
DateEndCredit	Дата окончания кредита	datetime
SumCredit	Общая сумма выданного кредита	float
NumPayment	Количество платежей по кредиту	int
SumPayment	Сумма всех произведенных платежей по кредиту	int
SumPercent	Общая сумма начисленных процентов по кредиту	int
AllCall	Количество звонков клиенту	int
SMSSucceeded	Количество успешно доставленных SMS	int
SMSFail	Количество неудачных попыток доставки SMS	int
SMSCanceled	Количество отмененных SMS	int
Letter	Количество отправленных бумажных писем	int
Email	Количество отправленных электронных писем	int

Матрица обычно представлена квадратом чисел, где каждая строка и столбец представляют отдельную переменную. Матрица корреляция для выбранных полей, представленных в таблице 2, показана на рисунке 1.




Рисунок 1 – Матрица корреляций

На диагонали матрицы (рис. 1) стоят единицы, так как корреляция переменной с самой собой равна 1. Числа не на диагонали показывают корреляцию между двумя переменными. Чем ближе значение к 1 или -1, тем сильнее связь между данными.

Важно понимать, что высокая корреляция между входными и выходными данными в обучающем наборе может стать источником проблемы, известной как переобучение. Переобучение возникает, когда модель слишком тесно прилагается к обучающим данным, запоминая их особенности и шум, вместо того чтобы извлекать общие закономерности, способные обобщаться на новые, ранее не виденные данные.

В результате модель будет хорошо работать на обучающих данных, но плохо на тестовых данных или на реальных данных, которые она не видела во время обучения. Также высокая корреляция между входными данными может затруднить обучение модели, поскольку она может привести к избыточности информации и уменьшить способность модели к обобщению [8]. Это может вызвать переобучение и снижение точности модели на новых данных. Чтобы решить эту проблему, важно использовать техники отбора признаков и регуляризации, а также анализировать корреляционную матрицу входных данных, чтобы определить любые избыточные или сильно коррелированные переменные.

Целевое значение, которое нас интересует, – это сумма платежей по кредиту (SumPayment). Если посмотреть на матрицу, то видно, что наиболее коррелирует с целевой переменной параметр, показывающий количество платежей (NumPayment), ведь чем больше платежей, тем больше и их сумма. Также высокая корреляция имеется между суммой процентов (SumProcent) и суммой кредита (SumCredit). Однако если обратим внимание на способы получения задолженности, а именно на количество звонков (AllCall), SMS-сообщений (SMSSucceeded), бумажных (Letter) и электронных (Email) писем, то заметим, что они практически не коррелируют с итоговой суммой платежей.

Поэтому можно рассмотреть их отдельно, построив, к примеру, гистограммы зависимостей количества звонков, SMS и писем от суммы платежей:




Рисунок 2 – Диаграмма зависимости суммы платежей от звонков

По рисунку 2 видно, что большое количество звонков не всегда может означать большой сбор по платежам. Высокие суммы находятся на показателях количества звонков в 10–15, 20–25 и 25–30. По такому же принципу рассмотрим и диаграммы по количеству SMS, бумажных писем и E-mail.

Аналогичным образом можно провести анализ для количества SMS (рис. 3), бумажных писем (рис. 4) и E-mail (рис. 5). Возможно, существует определенный порог частоты использования этих каналов коммуникации, при котором наблюдается максимальная эффективность в сборе платежей.

При этом, несмотря на интенсивность использования, эффективность сбора платежей может колебаться в зависимости от конкретного диапазона частоты. Анализ этих данных поможет выделить оптимальные стратегии коммуникации с клиентами для максимизации результатов по сбору платежей.




Рисунок 3 – Диаграмма зависимости суммы платежей от SMS




Рисунок 4 – Диаграмма зависимости суммы платежей от писем

Данные были собраны из двух баз данных организации и изначально представляют собой разрозненный и неструктурированный массив. Форматы полей различались, встречались пропуски, что делало их непригодными для анализа и построения моделей. В ходе подготовки данные были приведены к единому формату, очищены и нормализованы. В результате сформирован целостный набор из 4 000 строк и 56 признаков в формате CSV, пригодный для дальнейшей аналитики и выявления эффективных стратегий взаимодействия.




Рисунок 5 – Диаграмма зависимости суммы платежей от E-mail

ЗАКЛЮЧЕНИЕ

Одной из сильных сторон КА является наличие большого количества данных о должниках различного рода. Однако для эффективного использования их в совокупности с технологиями ИИ необходимо правильно преобразовать набор данных в обучающее множество, учитывая при этом формат их представления, размерности и взаимосвязи, чтобы контролировать обучаемость модели ИИ и корректность выходных значений.

Для подготовки обучающего множества были удалены ненужные данные (например, ID и номера договоров), типы данных приведены к числовому формату и проведена нормализация для лучшей обработки моделями ИИ.

На основе таблицы корреляции видно, что между значениями слабая линейная зависимость, что может свидетельствовать о более сложных взаимосвязях между данными, поэтому стоит делать выбор в пользу моделей ИИ, которые смогут их обрабатывать (например, нейронные сети).

Список источников

1. Федеральный закон «О защите прав и законных интересов физических лиц при осуществлении деятельности по возврату просроченной задолженности и о внесении изменений в Федеральный закон "О микрофинансовой деятельности и микрофинансовых организациях"» от 03.07.2016 № 230-ФЗ.
2. Корешкова, Е. С. Применение линейной модели множественной регрессии в экономических расчетах / Е. С. Корешкова, А. И. Ануфриева // *Фундаментальные научные исследования: теоретические и практические аспекты* : сборник материалов IV Международной научно-практической конференции, Кемерово, 31 мая 2017 года. – Кемерово: Общество с ограниченной ответственностью «Западно-Сибирский научный центр», 2017. – Т. II. – С. 417–420.
3. Багутдинов, Р. А. Методы интеграции, уменьшение размеров и нормализация обработки разнородных и разномасштабных данных / Р. А. Багутдинов, М. Ф. Степанов // *International Journal of Open Information Technologies*. – 2021. – № 2. – URL: <https://cyberleninka.ru/article/n/metody-integratsii-umenshenie-razmerov-i-normalizatsiya-obrabotki-raznorodnyh-i-raznomasshtabnyh-dannyh> (дата обращения: 16.01.2024).
4. Кретинина, Д. А. Применение нормализации данных на примере корпоративного хранилища данных банка / Д. А. Кретинина // *Актуальные проблемы прикладной математики, информатики и механики* : сборник трудов Международной научной конференции. – Воронеж: ООО «Велборн», 2024. – С. 1408–1410.
5. Соловьев, Д. С. Выбор наиболее эффективного метода нормализации данных в задаче принятия решений / Д. С. Соловьев // *Технологическая независимость и конкурентоспособность союзного государства, стран СНГ, ЕАЭС и ШОС* : сборник статей VI Международной научно-технической конференции. – Минск: Белорусский государственный технологический университет, 2023. – С. 438–441.
6. Семенова, В. А. Эвристика и численный метод нормализации эмпирического V^{TF} -контекста в онтологическом анализе данных / В. А. Семенова // *Информационные и математические технологии в науке и управлении*. – 2021. – № 2 (22). – С. 61–69.
7. Шустов, Д. А. Нормализация структур данных / Д. А. Шустов // *Экономика и социум*. – 2017. – № 5–2 (36). – URL: <https://cyberleninka.ru/article/n/normalizatsiya-struktur-dannyh> (дата обращения: 22.12.2023).

8. Саадалов, Т. Методика расчета коэффициента корреляции фехнера и пирсона, и их области применения / Т. Саадалов, Р. Мырзаibraimov, Ж. Д. Абдуллаева // Бюллетень науки и практики. – 2021. – № 10. – URL: <https://cyberleninka.ru/article/n/metodika-rascheta-koeffitsienta-korrelyatsii-fehnera-i-pirsona-i-ih-oblasti-primeneniya> (дата обращения: 21.12.2023).

References

1. *The Federal Law "On the Protection of the Rights and Legitimate Interests of Individuals when Carrying out Activities to Repay Overdue Debts and on Amendments to the Federal Law "On Microfinance Activities and Microfinance Organizations" dated 03.07.2016 № 230-FZ* (In Russ.).
2. Koreshkova, E. S., Anufrieva, A. I. *Application of the linear multiple regression model in economic calculations. Fundamental scientific research: theoretical and practical aspects : proceedings of the IV international scientific and practical conference, Kemerovo, May 31, 2017.* Kemerovo, Limited Liability Company "West Siberian Scientific Center", 2017, vol. II, pp. 417–420 (In Russ.).
3. Bagutdinov, R. A., Stepanov, M. F. Methods of integration, size reduction and normalization of processing of heterogeneous and multi-scale data. *International Journal of Open Information Technologies*, 2021, no. 2. Available at: <https://cyberleninka.ru/article/n/metody-integratsii-umenshenie-razmerov-i-normalizatsiya-obrabotki-raznorodnyh-i-raznomasshtabnyh-dannyh> (accessed 16.01.2024) (In Russ.).
4. Kretinina, D. A. Application of data normalization using the example of a bank's corporate data warehouse. *Current issues in applied mathematics, computer science and mechanics : proceedings of the international scientific conference. Voronezh: LLC "Velborn", 2024*, pp. 1408–1410 (In Russ.).
5. Solovov, D. S. Selecting the most effective data normalization method in a decision-making problem. *Technological independence and competitiveness of the Union State, the CIS countries, the EAEU and the SCO : collection of articles of the VI international scientific and technical conference. Minsk, Belarusian State Technological University, 2023*, pp. 438–441 (In Russ.).
6. Semenova, V. A. Heuristics and numerical method for normalizing the empirical context in ontological data analysis. *Information and Mathematical Technologies in Science and Management*, 2021, no. 2 (22), pp. 61–69 (In Russ.).
7. Shustov, D. A. Normalization of data structures. *Economics and Society*, 2017, no. 5–2 (36). Available at: <https://cyberleninka.ru/article/n/normalizatsiya-struktur-dannyh> (accessed 22.12.2023) (In Russ.).
8. Saadalov, T., Myrzaibraimov, R., Abdullayeva, Z. D. Method of calculating the correlation coefficient of fechner and pearson, and their fields of application. *Bulletin of Science and Practice*, 2021, no. 10. Available at: <https://cyberleninka.ru/article/n/metodika-rascheta-koeffitsienta-korrelyatsii-fehnera-i-pirsona-i-ih-oblasti-primeneniya> (accessed 21.12.2023) (In Russ.).

Статья поступила в редакцию 27.05.2025; одобрена после рецензирования 17.07.2025; принята к публикации 15.09.2025.

The article was submitted 27.05.2025; approved after reviewing 17.07.2025; accepted for publication 15.09.2025.

УДК 004.89

МЕТОДЫ ИДЕНТИФИКАЦИИ ЛИЧНОСТИ ПО ЛИЦУ В СИСТЕМАХ КОНТРОЛЯ ДОСТУПА: АНАЛИЗ И ПРОГРАММНАЯ РЕАЛИЗАЦИЯ ВЫБРАННОГО ПОДХОДА

Частикова Вера Аркадьевна, Кубанский государственный технологический университет, 350072, Российская Федерация, г. Краснодар, ул. Московская, 2,

кандидат технических наук, доцент ORCID: 0000-0003-2372-8275, e-mail: chastikova_va@mail.ru

Жерлицын Сергей Анатольевич, Кубанский государственный технологический университет, 350072, Российская Федерация, г. Краснодар, ул. Московская, 2,

аспирант кафедры кибербезопасности и защиты информации, ORCID: 0000-0003-3265-9873, e-mail: kpytooooo@gmail.com

Титова Анна Андреевна, Кубанский государственный технологический университет, 350072, Российская Федерация, г. Краснодар, ул. Московская, 2,

студент, e-mail: titova-aa@mail.ru

В статье рассматриваются существующие методы идентификации личности по лицу как на основе классических статистических моделей, так и на основе искусственных нейронных сетей, в том числе с использованием глубокого машинного обучения, а именно: метод идентификации по термограмме, скрытой Марковской модели, активных моделей внешнего вида, нейросетевых моделей AlexNet, DeepFace, DeepID, VGG-Face, FaceNet и MTCNN. Исследование предваряется анализом актуальности и востребованности систем идентификации личности по лицу, формулируются основные проблемы существующих решений. Описываются методологические основы работы подобных систем. На основе рассмотренных вариантов выделены их плюсы и минусы, проведен сравнительный анализ, и синтезирована архитектура глубокой модели с применением комбинации технологий многозадачных каскадных сверточных нейронных сетей и функции потерь ArcFace. Для получения высоких показателев эффективности предлагается использование сочетания триплетной функции потерь в совокупности с аддитивным угловым смещением для увеличения межклассовой различимости. Описан процесс апробации и экспериментальной оценки эффективности предложенной системы на датасетах Labeled Faces in the Wild (LFW) и YouTube Faces (YTF). Оценка проводится по трем критериям: точности, скорости и вычислительной нагрузке. По итогам анализа результатов разработанная система показывает более высокие результаты, чем остальные рассмотренные архитектуры по введенным критериям оценки.

Ключевые слова: биометрия, идентификация личности, машинное обучение, нейронные сети, информационная безопасность

FACE RECOGNITION METHODS IN ACCESS CONTROL SYSTEMS: ANALYSIS AND SOFTWARE IMPLEMENTATION OF THE SELECTED APPROACH

Chastikova Vera A., Kuban State Technological University, 2, Moskovskaya St., Krasnodar, 350072, Russian Federation

Cand. Sci. (Engineering), Assistant Professor, ORCID: 0000-0003-2372-8275, e-mail: chastikova_va@mail.ru

Zherlitsyn Sergey A., Kuban State Technological University, 2, Moskovskaya St., Krasnodar, 350072, Russian Federation

postgraduate student of the Department of Cybersecurity and Information Protection, ORCID: 0000-0003-3265-9873, e-mail: kpytooooo@gmail.com

Titova Anna A., Kuban State Technological University, 2, Moskovskaya St., Krasnodar, 350072, Russian Federation

student, e-mail: chastikova_va@mail.ru

This article examines existing face recognition methods for identity verification, including both classical statistical models and artificial neural networks, with an emphasis on deep machine learning techniques. The study covers identification methods based on thermograms, Hidden Markov Models, Active Appearance Models, as well as neural network architectures such as AlexNet, DeepFace, DeepID, VGG-Face, FaceNet, and MTCNN. The research begins with an analysis of the relevance and demand for facial recognition-based identity verification systems, outlining the main challenges of current solutions. The methodological foundations of such systems are described in detail. A comparative analysis of various approaches is conducted, highlighting their advantages and disadvantages. Based on this analysis, a deep learning model architecture is synthesized, integrating multi-task cascaded convolutional neural networks and the ArcFace loss function. To enhance performance, a combination of triplet loss with additive angular margin is proposed to increase inter-class separability. The process of validation and experimental evaluation of the proposed system is described, utilizing the Labeled Faces in the Wild (LFW) and YouTube Faces (YTF) datasets. The assessment is conducted according to three criteria: accuracy, execution speed, and computational load. The results demonstrate that the developed system outperforms other examined architectures across the specified evaluation metrics.

Keywords: biometrics, identity verification, machine learning, neural networks, information security

Graphical annotation (Графическая аннотация)



ВВЕДЕНИЕ

В условиях современных вызовов информационной безопасности защита данных приобретает критическую значимость, поскольку информация представляет собой ключевой ресурс для различных сфер деятельности. Увеличение объема данных сопровождается ростом и усложнением угроз, что делает задачи обеспечения безопасности информации приоритетными. Основной целью защиты данных является обеспечение корректного и безопасного доступа, исключающего несанкционированное использование.

Эффективное предотвращение несанкционированного доступа требует применения надежных методов идентификации в системах контроля доступа (СКУД), которые гарантируют уверенность в подлинности субъектов доступа.

Для реализации идентификации в рамках СКУД используются автономные носители признаков допуска или биометрические идентификаторы.

Биометрические системы идентификации объединяют в себе функции аутентификации, верификации и идентификации, каждая из которых имеет существенные различия. В процессе аутентификации биометрические данные сравниваются с заранее заданным шаблоном по модели 1:1. В то время как идентификация предполагает поиск соответствия среди всей базы данных по модели 1:N.

Согласно исследованию, проведенному редакцией журнала «Системы безопасности» [1, 2], основные сценарии применения биометрических систем идентификации включали: управление доступом на проходных (около 68 %) и контроль доступа в особо значимые зоны объектов (около 56 %). Также высокой эффективностью, по мнению респондентов, отличалось использование биометрических технологий в банковском секторе (29,7 %). Популярность и востребованность биометрических технологий в указанных направлениях продолжает расти ежегодно.

На современном этапе развития технологий биометрическая идентификация личности представляется наиболее надежным и перспективным методом обеспечения безопасности. Это обусловлено тем, что биометрические технологии обладают высокой эргономичностью и устойчивостью к угрозам, характерным для классических методов идентификации, таких как кража, утеря или несанкционированная передача. Более того, биометрические параметры напрямую связаны с уникальными характеристиками их владельца, что делает их неотделимыми от субъекта и обеспечивает высокую степень аутентичности.

ПОСТАНОВКА ЗАДАЧИ

Обеспечение защиты объектов требует комплексного подхода, включающего несколько уровней, среди которых ключевую роль играет система контроля и управления доступом (СКУД). СКУД обеспечивает защиту как материальных, так и информационных ресурсов предприятия, предотвращая несанкционированный доступ.

Биометрические устройства контроля доступа зарекомендовали себя как эффективные средства повышения уровня безопасности за счет предоставления доступа исключительно авторизованным лицам. Среди различных биометрических методов идентификации распознавание по лицу выделяется своей схожестью с естественным процессом идентификации человека. Однако данный метод сталкивается с рядом проблем, включая случаи, когда лицо частично закрыто различными предметами, такими как маски, очки или головные уборы. Эти факторы могут значительно усложнить процесс распознавания и снизить точность работы системы.

Системы распознавания лиц, используемые в рамках СКУД, должны эффективно решать задачу минимизации влияния закрывающих лицо объектов на точность идентификации. Это требует применения современных алгоритмов обработки изображений и глубокого обучения для повышения устойчивости систем к подобным искажениям. Таким образом, разработка и внедрение более совершенных технологий распознавания лиц остается актуальной задачей для повышения надежности и функциональности биометрических систем контроля доступа.

МЕТОДОЛОГИЧЕСКИЕ ОСНОВЫ РАСПОЗНАВАНИЯ ЛИЦ

Любая система может быть построена на основе трех принципов, характеризующих собственно процесс распознавания:

- 1) перечисление членов класса (когда каждый исходный класс данных идентифицируется списком содержащихся в нем изображений – членов класса);
- 2) общности свойств (когда каждый класс исходных данных характеризуется некоторыми общими свойствами, присущими всем его членам);
- 3) кластеризация (когда в исходном пространстве данных обнаруживается склонность к кластеризации).

В настоящее время идентификация по изображению лица достигла внушительного прогресса. Технологию распознавания лиц составляет любое устройство с цифровой фотографической технологией и современное ПО, основанное на обработке изображений и вычислении сложных математических алгоритмов.

Системы распознавания лиц захватывают входящее изображение с устройства камеры в двухмерном или трехмерном виде в зависимости от характеристик устройства.

Двухмерная (2D) технология распознавания лиц основана на плоских двумерных изображениях. Алгоритмы распознавания лиц используют: антропометрические параметры лица, графы – модели лиц или эластичные 2D-модели лиц, а также изображения с лицами, представленными некоторым набором физических или математических признаков [3]. Точность алгоритмов распознавания лиц рассматривается в таблице 1.

Основным преимуществом 2D-распознавания лиц является наличие готовых баз данных эталонных лиц и готовой инфраструктуры. Однако недостатком являются более высокие коэффициенты ошибок FAR и FRR по сравнению с 3D-распознаванием лиц.

3D-распознавание обычно выполняется после реконструированных трехмерных изображений. Технология 3D-распознавания лиц имеет более качественные характеристики. Хотя, очевидно, она тоже не идеальна.

Таблица 1 – Сравнительный анализ методов биометрической идентификации по изображению лица

Метод биометрической идентификации	FAR (коэффициент ложного допуска), %	FRR (коэффициент ложного отказа), %	Преимущества	Недостатки
2D-распознавание лиц	0,1	2,5	Простота реализации, широкая поддержка	Высокая чувствительность к углам обзора и освещению
3D-распознавание лиц	0,0005	0,1	Высокая точность, устойчивость к помехам	Высокая стоимость и сложность оборудования

Существуют различные технологии 3D-сканирования. Это могут быть лазерные сканеры с оценкой расстояния сканера до элементов поверхности объекта, специальные сканеры со структурированной подсветкой поверхности объекта и математической обработкой интерференционных кривых или сканеры, обрабатывающие синхронные стереопары изображений лица фотограмметрическим методом.

СУЩЕСТВУЮЩИЕ ПОДХОДЫ К ИДЕНТИФИКАЦИИ ПО ЛИЦУ

В ходе исследования были выявлены несколько подходов к решению поставленной задачи:

1. Метод идентификации по термограмме.

Основывается на регистрации теплового излучения лица. Тепловизионные камеры нечувствительны к внешнему освещению и улавливают лишь инфракрасное излучение, которое генерирует сам организм. Важное преимущество – способность отличать реальное лицо от фотографий и подделок, так как бумага или другие материалы имеют иное температурное распределение. Кроме того, макияж и неестественные пигменты меняют внешний вид в видимом диапазоне, но мало влияют на тепловую картину. Чтобы повысить точность анализа термограмм, применяют вейвлет-преобразования (например, Добеши или Хаара) и выделяют контуры ключевых областей лица с помощью операторов Робертса, Собеля или Кэнни. Операторы границ упрощают дальнейшие расчёты, отбрасывая избыточные детали фона и сохраняя контурную структуру. После выделения контуров к изображению применяют вейвлет-преобразование, что позволяет многократно снизить шум, выделить крупномасштабные признаки и тем самым облегчить процедуру сравнения лиц.

2. Скрытая Марковская модель (СММ).

Допускает, что система описывается последовательностью ненаблюдаемых (скрытых) состояний, между которыми происходят вероятностные переходы. Реально фиксируются лишь наблюдения – результат функции вероятностей от скрытых состояний. В теории распознавания лиц такие модели могут учитывать случайные факторы (освещение, поворот головы, выражение лица), но требуют точной априорной статистики и оптимизации множества параметров. Пока коммерческое применение СММ в задаче идентификации лиц ограничено.

3. Активные модели внешнего вида (ААМ).

ААМ объединяют статистическую модель формы и текстуры лица. На этапе обучения большое количество помеченных изображений лица (с отмеченными опорными точками, например, углами глаз и рта) приводят к стандарту масштаба и ориентации с помощью обобщенного Прокрустова анализа. Далее выполняется выделение главных компонент методом РСА, что помогает выделить вариации формы (жесткие и нежесткие деформации) и текстуры (цвет, тон).

Во время идентификации ААМ подбирает параметры формы и текстуры таким образом, чтобы минимизировать расхождение между синтезированным эталонным изображением и фактическим снимком. Преимуществом данного подхода является способность модели реконструировать форму лица даже при наличии искажений, а также возможность интерпретации результата, так как модель явно указывает на параметры, отвечающие за геометрические или текстурные деформации.

4. Методы на основе искусственных нейронных сетей (CNN).

Методы глубокого обучения стали революцией в области компьютерного зрения, особенно в распознавании изображений. Исторически первым значимым этапом на этом пути стал алгоритм Eigenfaces [4], предложенный в 1987 г., который открыл новые горизонты в идентификации лиц.

Алгоритм распознавания лица AlexNet

Прорыв в технологии распознавания лиц произошел с появлением AlexNet, представленного в 2012 г. на соревновании ImageNet Large Scale Visual Recognition Challenge [5]. Этот алгоритм стал знаковым вектором развития биометрических систем, популяризовав глубокое обучение в обработке изображений. AlexNet стал катализатором для разработки инновационных решений, что привело к существенному росту точности и масштабируемости систем глубокого обучения для распознавания лиц. Схема архитектуры приведена на рисунке 1.




Рисунок 1 – Схема архитектуры AlexNet

Структура AlexNet включает пять последовательных сверточных слоев, дополненных слоями подвыборки (pooling) и нормализации. Завершение модели осуществляется тремя полносвязными слоями, которые анализируют извлечённые признаки.

С момента внедрения AlexNet появилось множество усовершенствованных алгоритмов, включая DeepFace, DeepID, VGG-Face, FaceNet и ArcFace. Эти системы стали эталонами в области биометрии, обеспечив высокую точность (обогнав человеческие показатели) и эффективность в задачах идентификации и верификации.

Алгоритм распознавания лица DeepFace

DeepFace [6] представляет собой один из наиболее легких и универсальных алгоритмов для распознавания лиц и анализа их атрибутов. Технология интегрирует передовые модели искусственного интеллекта, обеспечивая автоматизацию всех процессов распознавания в фоновом режиме.

Ключевые функциональные возможности DeepFace включают верификацию, распознавание, анализ атрибутов, анализ в реальном времени.

Алгоритм распознавания лица DeepID

DeepID [7] стал одним из первых алгоритмов, применивших сверточные нейронные сети для задач распознавания лиц. Эта модель обеспечила производительность, превосходящую человеческие возможности, достигнув, например, точности 99,15 % на наборе данных Labeled Faces in the Wild (LFW) [8].

Архитектура DeepID включает несколько ключевых компонентов, оптимизирующих процесс извлечения признаков и их классификации. Алгоритм состоит из:

- сверточных слоев – отвечают за извлечение локальных признаков изображения;
- слоев подвыборки (Max-pooling) – производят уменьшение пространственных размеров признаков;
- глубоких скрытых слоев (Deep hidden identity features) – создают компактные представления лиц;
- Softmax-слоя – производит классификацию и окончательное принятие решения.

Рисунок 2 иллюстрирует последовательную работу всех уровней архитектуры, начиная с входного изображения и заканчивая финальной классификацией. Это позволяет эффективно решать задачи идентификации, верификации и анализа атрибутов с высокой точностью.




Рисунок 2 – Подробное описание технологии DeepID

Алгоритм распознавания лица VGG-Face

Архитектура VGG-Face, разработанная исследователями из группы Visual Geometry Group (VGG) Оксфордского университета, является одним из наиболее значимых достижений в области глубокого обучения. Эта модель основывается на использовании глубокой сверточной нейронной сети, которая демонстрирует выдающиеся результаты в задачах распознавания изображений. Известность VGG-Face обусловлена ее успехами на конкурсе ImageNet и высокими показателями точности в реальных приложениях [10].

Ключевая особенность архитектуры VGG заключается в упрощении структуры сети за счет использования исключительно сверточных слоев с небольшими ядрами (3×3) и слоев подвыборки (pooling), что обеспечивает высокую производительность при минимальной сложности настройки. Эта модульная структура позволяет VGG адаптироваться к различным задачам распознавания и обработки изображений.

В контексте распознавания лиц VGG-Face достигает точности 97,78 % на наборе данных Labeled Faces in the Wild (LFW), что подчеркивает ее эффективность в решении биометрических задач. Архитектура модели включает три основные группы слоев:

- слои свертки (Convolutional Layers) – служат для извлечения ключевых признаков изображения;
- слои подвыборки (Pooling Layers) – уменьшают размерности данных и повышают устойчивость к искажениям;
- полносвязные слои (Fully Connected Layers) с Softmax на выходе – предназначены для классификации по извлеченным признакам.

На рисунке 3 представлена визуализация архитектуры VGG-Face, которая иллюстрирует упорядоченное расположение слоев и их взаимодействие в сравнении с архитектурой AlexNet.

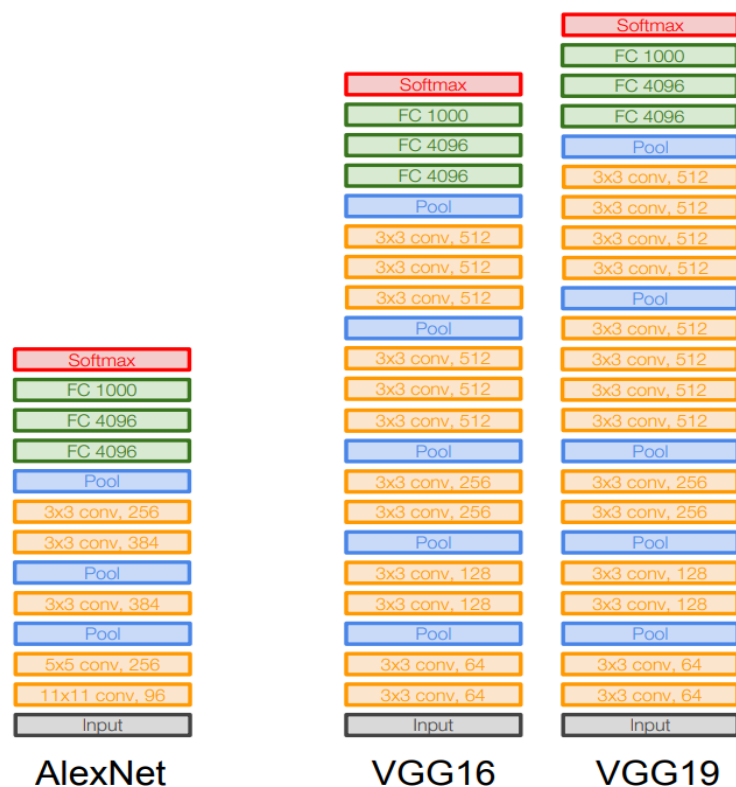


Рисунок 3 – Архитектуры AlexNet, VGG16 и VGG19

Алгоритм распознавания лица FaceNet

FaceNet, разработанный Google, представляет собой одну из наиболее современных и эффективных моделей для задач биометрии. Основу модели составляет глубокая сверточная нейронная сеть, использующая уникальную функцию потерь TripletLoss [12], схематически представленную на рисунке 4.

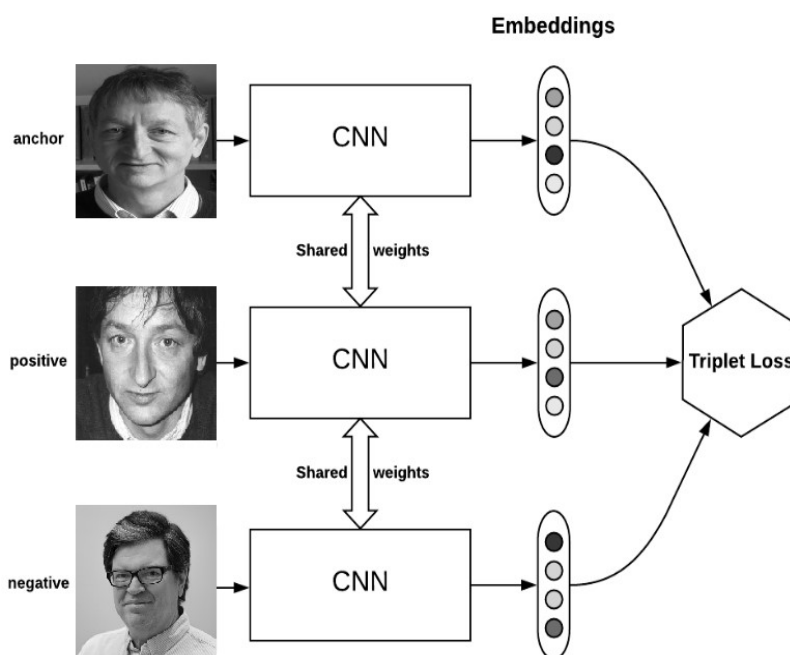


Рисунок 4 – Функция TripletLoss

Для обучения таких моделей используются так называемые полужесткие выборки (semi-hard sample), включающие такие триплеты, как якорный образец (anchor), позитивный образец (positive) и негативный образец (negative). Якорный и позитивный образцы относятся к одному классу, а негативный – к другому. Модель обучается таким образом, чтобы минимизировать расстояние между вложениями изображений одного человека, одновременно увеличивая расстояние между вложениями разных людей. Для достижения этого изображения проходят предварительную обработку, включая масштабирование, трансформацию и точное выравнивание области лица.

FaceNet решает задачи идентификации, верификации и кластеризации лиц. Каждый объект преобразуется в точку в евклидовом пространстве, где расстояние между точками отражает степень их сходства.

Принцип TripletLoss заключается в том, чтобы минимизировать расстояние между эмбедингом (embedding, свертка) якорного изображения и положительного изображения, одновременно увеличивая расстояние до эмбединга отрицательного изображения. Это позволяет эффективно разделять классы объектов в пространстве вложений.

Функция потерь триплета может быть формально определена, как:

$$\sum_i^N \left[\|f(x_i^a) - f(x_i^p)\|_2^2 - \|f(x_i^a) - f(x_i^n)\|_2^2 + \alpha \right]_+, \quad (1)$$

где x_i – изображение;

$f(x_i)$ – эмбединг изображения;

α – гиперпараметр, определяющий минимальную разницу между положительными и отрицательными парами [5].

В отличие от других методов, FaceNet сосредоточен на создании пространственных представлений или эмбедингов, которые универсальны и могут использоваться в различных задачах. Эта стратегия позволяет существенно улучшить производительность систем биометрической идентификации и повысить их устойчивость к искажениям. FaceNet предложил мощный, масштабируемый инструмент, который обеспечивает высокую точность и гибкость при решении задач идентификации, верификации и кластеризации.

Алгоритм распознавания лица MTCNN

Алгоритм MTCNN (Multi-Task Cascaded Convolutional Neural Networks) [9] представляет собой подход к обнаружению и выравниванию лиц, основанный на многозадачных каскадных сверточных нейронных сетях. Многозадачность заключается в одновременном определении ключевых точек лица и ограничивающих рамок, а каскадная структура подразумевает последовательную обработку данных с использованием трёх взаимосвязанных сетей: P-Net, R-Net и O-Net [11]. Архитектура всех 3-х сетей представлена на рисунке 5.

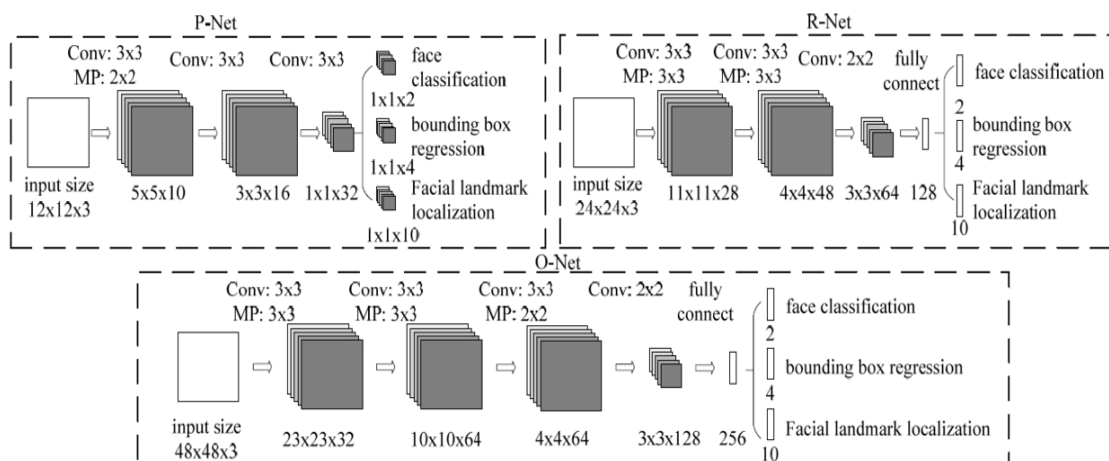


Рисунок 5 – Архитектура MTCNN

1. P-Net.

Proposal Network (сеть быстрого предложения) выполняет первичное обнаружение лиц. Для этого изображение масштабируется в несколько размеров, после чего P-Net сканирует каждый масштаб с помощью окна размером 12x12. Движение окна происходит с шагом в 2 пикселя, что позволяет охватить все возможные положения лица. На выходе P-Net генерирует: координаты ограничивающих рамок, которые обычно имеют более низкую точность, и уровни уверенности, отражающие вероятность наличия лица.

Эти значения обрабатываются по алгоритму Non-Maximum Suppression – взвешенной оценки

наиболее перспективных рамок с использованием функции softmax для классификации объектов.

2. R-Net.

Refinement Network (сеть уточнений) принимает результаты P-Net и использует окно размером 24×24 для уточнения координат ограничивающих рамок. Эта сеть отбрасывает ложноположительные результаты и фокусируется на наиболее вероятных рамках на наличие лица.

3. O-Net.

Output Network (выходная сеть) представляет собой завершающий этап алгоритма, использующий окно размером 48×48 для финальной обработки данных. На этом этапе сеть генерирует точные координаты ограничивающих рамок, определяет пять ключевых точек лица (такие как левый и правый глаза, нос и уголки рта).

MTCNN на текущий момент находит широкое применение в множестве различных областей. Компактная структура каскадных сетей обеспечивает высокую скорость сходимости моделей, что упрощает процесс их обучения. Применение каскадной обработки позволяет значительно повысить точность обнаружения, минимизируя вероятность ошибок. Кроме того, алгоритм характеризуется низкой вычислительной сложностью, что делает его эффективным для использования даже на устройствах с ограниченными ресурсами. В совокупности эти характеристики превращают MTCNN в один из наиболее востребованных инструментов для решения задач обнаружения и выравнивания лиц.

СРАВНИТЕЛЬНЫЙ АНАЛИЗ СУЩЕСТВУЮЩИХ МЕТОДОВ ИДЕНТИФИКАЦИИ ЛИЧНОСТИ ПО ИЗОБРАЖЕНИЮ ЛИЦА

Результаты сравнительного анализа методов идентификации личности по изображению лица, рассмотренных в предыдущем разделе, по наиболее значимым признакам приведены в таблице 2.

Таблица 2 – Сравнительный анализ методов идентификации по изображению лица

Критерий сравнения	Термо-грамма	СММ	ААМ	CNN
Низкая потребность к объему памяти	–	–	–	+
Отсутствие чувствительности к колебаниям температуры окружающей среды	–	+	+	+
Независимость от угла наклона головы	+	–	–	+
Устойчивость к окклюзиям	–	+	+	+
Независимость от освещения	+	+	+	+
Легкость интерпретации	–	–	+	+

Глубокие нейронные сети, в частности сверточные нейронные сети (CNN), выделяются как наиболее популярные и эффективные методы биометрической идентификации по изображению лица. Они демонстрируют высокую устойчивость к изменению температуры окружающей среды и уровню освещенности, а также успешно справляются с задачами распознавания лиц при наличии окклюзий. Это делает их особенно актуальными для современных приложений. Дополнительно результаты, генерируемые CNN, легко интерпретируемы благодаря их представлению в удобной для человека форме [5]. Таким образом, сверточные нейронные сети остаются доминирующим инструментом в области биометрической идентификации.

ПРЕДЛАГАЕМАЯ АРХИТЕКТУРА

Одним из центральных вызовов, связанных с использованием глубоких сверточных нейронных сетей (ГСНС) в задачах распознавания лиц, является проектирование функций потерь, способных повысить дискриминационные свойства извлекаемых признаков. Эффективным решением в этом контексте может служить функция потерь центра, которая направлена на уменьшение расстояния между признаками внутри классов в евклидовом пространстве, что способствует их высокой компактизации.

В текущей практике выделяют два основных подхода к обучению ГСНС для биометрической идентификации. Первый подход базируется на применении многоклассовых классификаторов, таких как softmax, для разделения идентификаторов в обучающих наборах. Второй подход предполагает изучение пространственных представлений (эмбедингов) с использованием специализированных функций потерь, включая триплетную функцию. Оба метода, опирающиеся на сложные алгоритмические конструкции и тщательный анализ данных, демонстрируют значительные успехи в задачах идентификации лиц.

Однако каждое из направлений имеет свои ограничения. Для классификаторов, основанных на softmax, характерно линейное увеличение размерности матрицы параметров с ростом числа идентификаторов, что существенно затрудняет работу с большими наборами данных. Кроме того, формируемые признаки часто недостаточно различимы для сценариев с открытым набором данных, несмотря на их эффективность для задач классификации с фиксированным множеством классов.

В случае триплетной функции потерь основными проблемами выступают комбинаторный

взрыв числа триплетов при увеличении объема данных, что значительно замедляет процесс обучения, а также сложность в отборе полужестких выборок, необходимых для оптимального функционирования модели.

Устранение данных ограничений и разработка новых архитектур функций потерь представляют собой ключевые задачи, направленные на дальнейшее улучшение эффективности методов распознавания лиц, основанных на глубоких нейронных сетях.

Наиболее широко применяемая классификационная функция потерь softmax loss представляется следующим образом:

$$L_1 = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{W_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^n e^{W_j^T x_i + b_j}}, \quad (2)$$

где $x_i \in \mathbb{R}^d$ обозначает вектор признаков i -го образца, принадлежащий y_i -му классу. Размер эмбединга d принимается равным эмпирически полученному в ходе экспериментов значению 512. $W_j \in \mathbb{R}^d$ обозначает j -й столбец веса $W \in \mathbb{R}^{d \times n}$, а $b_j \in \mathbb{R}^n$ – значение биаса (нейрона смещения). Размер батча и номер класса равны N и n соответственно. Традиционная функция потерь softmax loss широко используется в глубоких нейросетях для распознавания лиц, однако она явно не оптимизирует эмбединги для обеспечения высокой внутриклассовой компактности и межклассовой различимости, что ограничивает ее производительность в условиях значительных внутриклассовых вариаций (например, изменения позы) и крупномасштабных сценариев (миллионы или триллионы пар).

Для упрощения предполагается $b_j = 0$. Тогда логит можно преобразовать как $W_{y_i}^T x_i = \|W_{y_i}\| \|x_i\| \cos \theta_{y_i}$, где θ_{y_i} – угол между весом W_{y_i} и признаком x_i . Индивидуальный вес был зафиксирован в значении $\|W_j\| = 1$ с помощью l_2 -нормализации. Аналогичным образом зафиксирована функция встраивания $\|x_i\|$ с помощью нормализации l_2 и отмасштабирована до s . Шаг нормализации признаков и весов делает прогнозы зависимыми только от угла между признаком и весом. Полученные таким образом эмбединги распределяются по гиперсфере радиусом s , а функция потерь приобретает вид:

$$L = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s \cos \theta_{y_i}}}{e^{s \cos \theta_{y_i}} + \sum_{j=1, j \neq y_i}^n e^{s \cos \theta_j}}. \quad (3)$$

Для повышения межклассовой различимости без потери точности идентификации была предложена функция потерь с аддитивным угловым смещением – ArcFace [12]. Её основная идея заключается в добавлении фиксированного углового смещения между вектором весов и вектором признаков, что обеспечивает лучшее разграничение классов. Формула функции потерь ArcFace выглядит следующим образом:

$$L = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s(\cos(\theta_{y_i} + m))}}{e^{s(\cos(\theta_{y_i} + m))} + \sum_{j=1, j \neq y_i}^n e^{s \cos \theta_j}}. \quad (4)$$

На рисунке 6 представлена визуализация вычисления логита в архитектуре глубокой сверточной нейронной сети, применяемой для задачи распознавания лиц с использованием функции потерь ArcFace. Процесс начинается с нормализации вектора признаков x_i и весового вектора $\|W_j\|$, что позволяет выразить их скалярное произведение в виде косинуса угла между ними $\cos \theta_{y_i}$. После этого функция арккосинуса используется для вычисления угла θ_{y_i} между нормализованными векторами. Затем к целевому углу добавляется фиксированный угловой запас m , который увеличивает межклассовую дистанцию. Результирующее значение преобразуется в логит, а все логиты масштабируются с использованием функции softmax.




Рисунок 6 – Обучение ГСНС распознаванию лиц (ArcFace)

Потеря softmax обеспечивает разделение классов в пространстве признаков, но границы решений часто остаются неоднозначными.

Для классического Softmax вероятность ошибки определяется как:

$$P_{softmax\ error} = P\left(s \cdot \cos(\theta_{y_i}) \leq \max_{j \neq y_i} s \cdot \cos(\theta_j)\right). \quad (5)$$

Для ArcFace вероятность ошибки:

$$P_{ArcFace\ error} = P\left(s \cdot \cos(\theta_{y_i} + m) \leq \max_{j \neq y_i} s \cdot \cos(\theta_j)\right). \quad (6)$$

Так как функция косинуса убывает на $[0, \pi]$, то:

$$\cos(\theta_{y_i} + m) < \cos(\theta_{y_i}), \quad \forall \theta_{y_i} \in [0, \pi - m]. \quad (7)$$

Это означает, что логит целевого класса в ArcFace всегда меньше, чем в Softmax, а значит, вероятность того, что он окажется ниже, чем логиты других классов, уменьшается.

Рассмотрим вероятность того, что правильный класс будет выбран при использовании softmax:

$$P_{softmax\ correct} = \frac{e^{s \cdot \cos(\theta_{y_i})}}{e^{s \cdot \cos(\theta_{y_i})} + \sum_{j \neq y_i} e^{s \cdot \cos(\theta_j)}}. \quad (8)$$

Для ArcFace:

$$P_{ArcFace\ correct} = \frac{e^{s \cdot \cos(\theta_{y_i} + m)}}{e^{s \cdot \cos(\theta_{y_i} + m)} + \sum_{j \neq y_i} e^{s \cdot \cos(\theta_j)}}. \quad (9)$$

Так как $\cos(\theta_{y_i} + m) < \cos(\theta_{y_i})$, то

$$e^{s \cdot \cos(\theta_{y_i} + m)} < e^{s \cdot \cos(\theta_{y_i})}. \quad (10)$$

Однако следует отметить, что числитель уменьшился, но вероятность выбора неправильного класса зависит от разницы в числителе и знаменателе. Так как $\sum_{j \neq y_i} e^{s \cdot \cos(\theta_j)}$ не изменились, а второе слагаемое в знаменателе также стало меньше, то вероятность выбора неверного класса уменьшится. Таким образом, получаем, что

$$P_{ArcFace\ correct} > P_{softmax\ correct} \rightarrow P_{ArcFace\ error} < P_{softmax\ error}. \quad (11)$$

Функция потерь ArcFace значительно улучшает межклассовую различимость, создавая более выраженные разрывы между соседними классами.

Каждая точка на дуге представляет пространство значений, соответствующее одному образцу, а линии указывают якорное направление для каждого класса. Благодаря нормализации векторов и их проецирования в пространство фиксированного радиуса, функция ArcFace формирует классы с явным увеличением пространственного разрыва между ближайшими классами, что повышает точность классификации и устойчивость модели.

АПРОБАЦИЯ И АНАЛИЗ РЕЗУЛЬТАТОВ

Обучение моделей проводилось с использованием широко известных наборов данных LFW и YTF (YouTube Faces) [13], являющихся эталоном для тестирования систем идентификации лиц в статичных изображениях и видеозаписях. Набор данных LFW содержит 13 233 изображения, охватывающие 5749 уникальных личностей, взятых из открытых источников, с разнообразием поз, мимики и условий освещения. В свою очередь, YTF включает 3425 видеороликов, относящихся к 1595 различным людям, при среднем числе видеозаписей на одну личность, равном 2,15. Длительность видео колеблется в диапазоне от 48 до 6070 кадров, с усредненной длиной около 181 кадра.

Для анализа эффективности тестируемых нейросетевых технологий были выбраны три ключевых критерия, направленных на комплексную оценку алгоритмов: точность распознавания как основной показатель качества работы становится особенно важной при сложных условиях, таких как окклюзии или значительные вариации поз; скорость работы алгоритмов, играющая решающую роль в приложениях реального времени, так как она определяет их практическую ценность в условиях высоких нагрузок; вычислительная нагрузка, которая, в свою очередь, является критически важным фактором для обеспечения стабильной работы системы, так как алгоритм должен эффективно обрабатывать большие объемы данных с минимальным воздействием на производительность оборудования [14, 15].

На рисунке 7 представлено сравнение нейросетевых методов по точности, скорости и вычислительной нагрузке соответственно.




Рисунок 7 – Сравнительный анализ алгоритмов по точности распознавания, времени обработки и вычислительной нагрузке

Как видно из графиков, предложенная архитектура показывает лучшие результаты по выбранным характеристикам.

ВЫВОДЫ

Анализ результатов апробации выявил, что комбинация алгоритмов MTCNN и ArcFace демонстрирует превосходство над альтернативными подходами, обеспечивая наиболее высокие показатели как на датасете LFW, так и на YTF. Высокая эффективность данной совокупности достигается благодаря введению аддитивного углового штрафа, который существенно повышает дискриминационные свойства извлеченных признаков.

Таким образом, на основании проведенного анализа нейросетевых технологий комбинация MTCNN и ArcFace была выбрана в качестве наиболее оптимального решения. Она превосходит другие подходы как по точности, так и по эффективности, что делает ее идеальной для приложений, требующих работы в режиме реального времени.

Реализованный в рамках исследования программный комплекс продемонстрировал способность идентифицировать личность с низким процентом ошибок: 0,2 % без использования маски и 0,42 % при наличии маски, что подтверждает его высокую практическую ценность.

Список источников

1. Ryu, R. The design and evaluation of adaptive biometric authentication systems: Current status, challenges and future direction / R. Ryu, S. Yeom, D. Herbert, Ju. Dermoudy // *ICT Express*. – 2023. – Vol. 9, № 6. – P. 1183–1197. – DOI: 10.1016/j.icte.2023.04.003. – EDN TOXQPI.
2. Горшков, А. Биометрическая идентификация. 101 ответ в помощь разработчикам и заказчикам / А. Горшков // *Системы безопасности*. – Вып. 6. – URL: <https://www.secuteck.ru/articles/biometricheskaya-identifikaciya-101-otvet-v-pomoshch-razrabotchikam-i-zakazchikam>.
3. Частикова, В. А. Аналитический обзор методов идентификации личности на основе биометрических характеристик / В. А. Частикова, А. А. Титова, Д. О. Войлова // *Вестник Адыгейского государственного университета*. Серия 4: Естественно-математические и технические науки. – 2022. – № 1 (296). – С. 92–112.
4. Choi, H. A Novel Quick-Response Eigenface Analysis Scheme for Brain-Computer Interfaces / H. Choi, Ju. Park, Ye. Mo. Yang // *Sensors*. – 2022. – Vol. 22, № 15. – P. 5860. – DOI 10.3390/s22155860. – EDN YFZAZY.
5. Титова, А. А. Интеллектуальная система биометрической идентификации личности. Разработка методики на основе физиологических характеристик: дипломная работа по специальности 10.05.03 «Информационная безопасность автоматизированных систем» / А. А. Титова. – Краснодар : Кубанский государственный технологический университет, 2022.
6. Alexandrov, D. V. Overview of Face Recognition Algorithms for Person Identification / D. V. Alexandrov // *Programmnaia Ingeneria*. – 2022. – Vol. 13, № 7. – P. 331–343. – DOI 10.17587/prin.13.331-343. – EDN EUFFYZ.
7. Ouyang, W. DeepID-Net: Object Detection with Deformable Part Based Convolutional Neural Networks / W. Ouyang, X. Zeng, X. Wang [et al.] // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2017. – Vol. 39, № 7. – P. 1320–1334. – DOI 10.1109/TPAMI.2016.2587642. – EDN KTFZVJ.
8. Sikha, O. K. VGG16-random fourier hybrid model for masked face recognition / O. K. Sikha, B. Bharath // *Soft Computing – A Fusion of Foundations, Methodologies and Applications*. – 2022. – Vol. 26, № 22. – P. 12795–12810. – DOI 10.1007/s00500-022-07289-0. – EDN IVRTJY.
9. Huang, Gary B. Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments : technical report 07-49 / Gary B. Huang, Manu Ramesh, Tamara Berg, and Erik Learned-Miller. – Amherst : University of Massachusetts, October, 2007.
10. Chunming, Wu. MTCNN and FACENET Based Access Control System for Face Detection and Recognition / Chunming Wu, Ying Zhang // *Automatic Control and Computer Sciences*. – 2021. – Vol. 55, № 1. – P. 102–112. – DOI 10.3103/S0146411621010090. – EDN YBHHWB.
11. Khan, S. S. MTCNN++: A CNN-based face detection algorithm inspired by MTCNN / S. S. Khan, D. Sengupta, A. Ghosh, A. Chaudhuri // *The Visual Computer*. – 2024. – Vol. 40, № 2. – P. 899–917. – DOI 10.1007/s00371-023-02822-0. – EDN KJVGON.
12. Khan, S. S. MTCNN++: A CNN-based face detection algorithm inspired by MTCNN / S. S. Khan, D. Sengupta, A. Ghosh et al. *Vis. Comput.* – 2024. – Vol. 40. – P. 899–917. – URL: <https://doi.org/10.1007/s00371-023-02822-0>
13. ArcFace: Additive Angular Margin Loss for Deep Face Recognition. – URL: <https://arxiv.org/abs/1801.07698/> (дата обращения: 13.05.2022).
14. Lior, Wolf. Face Recognition in Unconstrained Videos with Matched Background Similarity / Lior Wolf, Tal Hassner and Itay Maoz // *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*. – 2011.
15. Chastikova, V. A. Development of a personal identification technique for automation systems / V. A. Chastikova, S. A. Zherlitsyn, Y. I. Volya // *IOP Conference Series : Materials Science and Engineering*, Krasnoyarsk, 20–21 ноября 2020 года / Krasnoyarsk Science and Technology City Hall. – Krasnoyarsk, Russian Federation : IOP Publishing Ltd, 2021. – Vol. 1047. – P. 12138. – DOI: 10.1088/1757-899X/1047/1/012138. – EDN NYJLDM.
16. Chastikova, V. A. Analysis of training of deep neural networks with heterogeneous architecture while detecting malicious network traffic / V. A. Chastikova, S. A. Zherlitsyn, Y. I. Volya, V. V. Sotnikov // *IOP Conference Series : Materials Science and Engineering*, Krasnoyarsk, 20–21 ноября 2020 года / Krasnoyarsk Science and Technology City Hall. – Krasnoyarsk, Russian Federation: IOP Publishing Ltd, 2021. – Vol. 1047. – P. 12135. – DOI: 10.1088/1757-899X/1047/1/012135. – EDN LHOUYQ.

References

1. Ryu, R., Yeom, S., Herbert D., Dermoudy, Ju. The design and evaluation of adaptive biometric authentication systems: Current status, challenges and future direction. *ICT Express*, 2023, vol. 9, no. 6, pp. 1183–1197. DOI: 10.1016/j.icte.2023.04.003. EDN TOXQPI.
2. Gorshkov, A. Biometric Identification. 101 Answers for Developers and Customers. *Security Systems Journal*, issue 6. Available at: <https://www.secuteck.ru/articles/biometricheskaya-identifikaciya-101-otvet-v-pomoshch-razrabotchikam-i-zakazchikam> (In Russ.).
3. Chastikova, V. A., Titova, A. A., Voilova, D. O. Analytical Review of Personal Identification Methods Based on Biometric Characteristics. *Bulletin of the Adyge State University. Series 4: Natural and Technical Sciences*, 2022. no. 1 (296), pp. 92–112 (In Russ.).
4. Choi, H., Park, Ju., Yang, Ye. Mo. A Novel Quick-Response Eigenface Analysis Scheme for Brain-Computer Interfaces. *Sensors*, 2022, vol. 22, no. 15, p. 5860. DOI 10.3390/s22155860. EDN YFZAZY.
5. Titova, A. A. *Intelligent Biometric Personal Identification System. Methodology Development Based on Physiological Characteristics: Graduate Thesis in the field of 10.05.03 “Information Security of Automated Systems”*. Krasnodar, Kuban State Technological University, 2022 (In Russ.).

6. Alexandrov, D. V. Overview of Face Recognition Algorithms for Person Identification. *Programmnaya Ingeneria*, 2022, vol. 13, no. 7, p. 331–343. DOI 10.17587/prin.13.331-343. EDN EUFFYZ.
7. Ouyang, W., Zeng, X., Wang, X. [et al.]. DeepID-Net: Object Detection with Deformable Part Based Convolutional Neural Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, vol. 39, no. 7, pp. 1320–1334. DOI 10.1109/TPAMI.2016.2587642. EDN KTFZVJ.
8. Sikha, O. K. B. Bharath VGG16-random fourier hybrid model for masked face recognition. *Soft Computing – A Fusion of Foundations, Methodologies and Applications*, 2022, vol. 26, no. 22, pp. 12795–12810. DOI 10.1007/s00500-022-07289-0. EDN IVRTJY.
9. Gary B. Huang, Manu Ramesh, Tamara Berg, and Erik Learned-Miller. *Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments : technical report 07-49*. Amherst, University of Massachusetts, October, 2007.
10. Chunming, Wu., Ying, Zhang MTCNN and FACENET Based Access Control System for Face Detection and Recognition. *Automatic Control and Computer Sciences*, 2021, vol. 55, no. 1, pp. 102–112. DOI 10.3103/S0146411621010090. EDN YBHWWB.
11. Khan, S. S., Sengupta, D., Ghosh, A., Chaudhuri, A. MTCNN++: A CNN-based face detection algorithm inspired by MTCNN. *The Visual Computer*, 2024, vol. 40, no. 2, pp. 899–917. DOI 10.1007/s00371-023-02822-0. EDN KJVGON.
12. Khan, S. S., Sengupta, D., Ghosh, A. et al. MTCNN++: A CNN-based face detection algorithm inspired by MTCNN. *Vis. Comput.*, 2024, 40, 899–917 <https://doi.org/10.1007/s00371-023-02822-0>
13. ArcFace: Additive Angular Margin Loss for Deep Face Recognition. Available at: <https://arxiv.org/abs/1801.07698/> (accessed 13.05.2022).
14. Lior, Wolf, Tal, Hassner and Itay, Maoz. Face Recognition in Unconstrained Videos with Matched Background Similarity. *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2011.
15. Chastikova, V. A., Zherlitsyn, S. A., Volya, Y. I. Development of a personal identification technique for automation systems. *IOP Conference Series: Materials Science and Engineering, Krasnoyarsk, November 20–21, 2020, Krasnoyarsk Science and Technology City Hall*. Krasnoyarsk, Russian Federation, IOP Publishing Ltd, 2021, vol. 1047, p. 12138. DOI: 10.1088/1757-899X/1047/1/012138. EDN NYJLDM.
16. Chastikova, V. A., Zherlitsyn, S. A., Volya, Y. I., Sotnikov, V. V. Analysis of training of deep neural networks with heterogeneous architecture while detecting malicious network traffic. *IOP Conference Series: Materials Science and Engineering, Krasnoyarsk, November 20–21, 2020, Krasnoyarsk Science and Technology City Hall*. Krasnoyarsk, Russian Federation: IOP Publishing Ltd, 2021, vol. 1047, p. 12135. DOI 10.1088/1757-899X/1047/1/012135. EDN LHOUYQ.

Статья поступила в редакцию 28.03.2025; одобрена после рецензирования 28.05.2025; принята к публикации 09.06.2025.

The article was submitted 28.03.2025; approved after reviewing 28.05.2025; accepted for publication 09.06.2025.

УДК 303.44

**СРАВНИТЕЛЬНЫЙ АНАЛИЗ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ
ДЛЯ ПРОГНОЗИРОВАНИЯ ЯВКИ ПРАВОНАРУШИТЕЛЕЙ В СУД**

Михайлик Владимир Анатольевич, Астраханский государственный университет имени В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, магистрант, ORCID: 0009-0002-4692-6346, e-mail: otola_han@mail.ru.

Демина Раиса Юрьевна, Астраханский государственный технический университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 16/1, кандидат технических наук, доцент, ORCID: 0009-0009-1615-5641, e-mail: raisa.demina.91@mail.ru

Меркулова Аlesia Михайловна, Астраханский государственный университет имени В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, старший преподаватель, ORCID: 0009-0004-6258-6067, e-mail: alesya_m-d@mail.ru

Руденко Михаил Федорович, Астраханский государственный технический университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 16/1, доктор технических наук, профессор, ORCID: 0000-0002-5150-5709, e-mail: mf.rudenko@mail.ru

В статье представлены результаты разработки и сравнительного анализа моделей прогнозирования явки правонарушителей в суд с применением методов машинного обучения. Проведена оценка эффективности пяти алгоритмов: деревья решений (J48, REPTree), алгоритм на основе правил (PART), ансамблевый метод (Bagging) и метод k-ближайших соседей (IBk). При анализе использовались комплексные метрики качества, включая точность классификации, полноту, точность предсказаний, F-меру и площадь под ROC-кривой. В результате исследования выявлено, что ансамблевый метод Bagging демонстрирует наилучшие показатели с точностью классификации 80,2 % и высокими значениями площади под ROC-кривой ($> 0,91$). Разработанная модель может быть использована для оптимизации работы судебной системы, рационального распределения ресурсов и повышения эффективности судопроизводства.

Ключевые слова: явка в суд, прогнозирование, машинное обучение, бинарная классификация, деревья решений, Bagging, метрики классификации, ROC-кривая

**COMPARATIVE ANALYSIS OF PREDICTIVE MODELS FOR OFFENDERS' COURT
APPEARANCE BASED ON MACHINE LEARNING METHODS**

Mikhailik Vladimir A., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 114056, Russian Federation, master's student, e-mail: otola_han@mail.ru

Demina Raisa Yu., Astrakhan State Technical University, 16 Tatishchev St., Astrakhan, 414056, Russian Federation, Cand. Sci. (Engineering), Associate Professor, ORCID: 0009-0009-1615-5641, e-mail: raisa.demina.91@mail.ru

Merkulova Alesya M., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 114056, Russian Federation, Senior Lecturer, ORCID: 0009-0004-6258-6067, e-mail: alesya_m-d@mail.ru

Rudenko Mihail F., Astrakhan State Technical University, 16 Tatishchev St., Astrakhan, 414056, Russian Federation, Doct. Sci. (Engineering), Associate Professor, ORCID: 0000-0002-5150-5709, e-mail: mf.rudenko@mail.ru

The article presents the results of developing and comparative analysis of predictive models for offenders' court appearance using machine learning methods. The effectiveness of five algorithms evaluated: decision trees (J48, REPTree), rule-based algorithm (PART), ensemble method (Bagging), and k-nearest neighbors method (IBk). The analysis employed comprehensive quality metrics, including classification accuracy, recall, precision, F-measure, and area under the ROC curve. The study revealed that the Bagging ensemble method demonstrates the best performance with a classification accuracy of 80.2 % and high values of the area under the ROC curve (> 0.91). The developed model can be used to optimize the operation of the judicial system, rational allocation of resources, and increasing the efficiency of judicial proceedings.

Keywords: court appearance, prediction, machine learning, binary classification, decision trees, Bagging, classification metrics, ROC curve

ВВЕДЕНИЕ

Эффективность судебной системы существенно зависит от своевременной явки всех участников процесса, особенно правонарушителей. Неявка фигурантов приводит к срыву заседаний, дополнительной нагрузке на судей и аппарат суда, а также влечет за собой значительные материальные и временные затраты. Проблема особенно актуальна в условиях растущей нагрузки на судебную систему и ограниченности ресурсов.

Прогнозирование явки правонарушителей в суд позволяет оптимизировать процесс рассмотрения дел, минимизировать задержки и повысить эффективность работы судов. Факторы, влияющие на явку правонарушителей в суд, сгруппированы по:

- 1) характеру правонарушения – более тяжкие преступления могут приводить к более высокой явке (из-за страха усиления наказания), но также могут повышать риск побега;
- 2) личности подсудимого – возраст, социальный статус, наличие семьи, работы, судимостей;
- 3) мере пресечения – если человек находится под подпиской о невыезде, под залогом или под домашним арестом, вероятность явки выше;
- 4) срокам уведомления – если повестка пришла заранее, шансы на явку увеличиваются;
- 5) социально-экономическим факторам – безработные или лица без постоянного места жительства чаще не являются;
- 6) правовой осведомленности – знание последствий неявки (заочное рассмотрение, привод, штраф, арест);
- 7) истории явки – если подсудимый ранее уже пропускал заседания, вероятность повторной неявки выше.

В предыдущих исследованиях автором был проведен анализ факторов, влияющих на явку правонарушителей в суд [1–3]. Были рассмотрены такие характеристики, как пол, возраст, наличие рецидивов и предыдущих неявок. Данный анализ позволил сформировать основу для построения прогностических моделей, способных с высокой точностью предсказывать вероятность явки конкретного правонарушителя.

Целью настоящего исследования является сравнительный анализ моделей прогнозирования явки правонарушителей в суд с использованием различных алгоритмов машинного обучения. Акцент сделан на выборе модели, обеспечивающей не только высокую точность прогнозирования, но и приемлемый уровень интерпретируемости результатов.

Точный прогноз вероятности явки позволит разрабатывать персонализированные подходы к информированию правонарушителей о необходимости явки, оптимизировать планирование судебных заседаний и рационально распределять ресурсы для обеспечения явки.

ВЫБОР АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

Для решения задачи прогнозирования явки правонарушителей в суд, формулируемой как задача бинарной классификации (класс «явка» или класс «неявка»), были выбраны пять алгоритмов машинного обучения, представляющих различные подходы:

1. J48 – реализация алгоритма C4.5 для построения деревьев решений. Данный алгоритм обладает высокой интерпретируемостью и способностью работать с разнородными данными. J48 использует концепцию информационного прироста для выбора наиболее значимых признаков при построении дерева.
2. REPTree (Reduced Error Pruning Tree) – алгоритм быстрого построения дерева решений с редукцией ошибок для предотвращения переобучения. REPTree строит дерево на основе информационного прироста, а затем выполняет процедуру «обрезки», удаляя поддеревья, не улучшающие обобщающую способность модели [4].
3. PART (Projected Aggregated Recursive Tree) – алгоритм генерации набора правил классификации на основе построения частичных деревьев решений. PART извлекает правила по одному, выбирая наиболее точное правило на каждом шаге, и удаляет случаи, покрываемые этим правилом [5].
4. Bagging (Bootstrap Aggregating) – ансамблевый метод, направленный на повышение стабильности и точности алгоритмов машинного обучения. Bagging создает множество моделей на различных подвыборках данных и агрегирует их предсказания, что обычно приводит к улучшению обобщающей способности и снижению дисперсии ошибок [6].
5. IBk (k-Nearest Neighbors) – алгоритм классификации на основе поиска k ближайших соседей. IBk является «ленивым» алгоритмом, который не строит явную модель в процессе обучения, а хранит обучающие примеры и классифицирует новые случаи на основе их сходства с известными [7].

Выбор данных алгоритмов обусловлен их различными подходами к решению задачи классификации, что позволяет провести всесторонний анализ и выбрать наиболее подходящий метод для конкретной задачи прогнозирования явки в суд.

МЕТРИКИ ОЦЕНКИ КАЧЕСТВА МОДЕЛЕЙ

Для объективной и комплексной оценки качества моделей использовался расширенный набор метрик [8]:

1. Доля правильно классифицированных объектов (Accuracy).
2. Матрица ошибок (Confusion Matrix).
3. True Positive (TP) – количество правильно предсказанных явок.
4. True Negative (TN) – количество правильно предсказанных неявок.
5. False Positive (FP) – количество ошибочно предсказанных явок.
6. False Negative (FN) – количество ошибочно предсказанных неявок.
7. Точность (Precision) – доля истинно положительных результатов среди всех положительных предсказаний модели. Высокая точность означает, что при предсказании моделью «явки» это предсказание с высокой вероятностью окажется верным.

8. Полнота (Recall) – доля истинно положительных результатов среди всех фактических положительных случаев. Высокая полнота означает, что модель способна выявить большинство реальных случаев явки.

9. F-мера (F-Measure) – гармоническое среднее между точностью и полнотой, обеспечивающее сбалансированную оценку качества модели, особенно полезную при несбалансированных классах.

10. Площадь под ROC-кривой (ROC Area) – интегральная характеристика, оценивающая способность модели различать классы при различных порогах классификации. Значение, близкое к 1, указывает на отличное качество классификации.

11. Площадь под PR-кривой (PRC Area) – площадь под кривой «точность-полнота», особенно информативная при несбалансированных классах.

Для обеспечения надежности оценок использовалась 10-кратная кросс-валидация: исходный набор данных разделялся на 10 равных частей, где 9 частей использовались для обучения, а оставшаяся – для тестирования. Процедура повторялась 10 раз с различными разбиениями, а результаты усреднялись, что обеспечивало более стабильную и репрезентативную оценку обобщающей способности моделей.

Результаты исследования

Сравнительный анализ алгоритмов машинного обучения

В таблице 1 представлены результаты сравнительной оценки эффективности выбранных алгоритмов машинного обучения для задачи прогнозирования явки правонарушителей в суд.

Таблица 1 – Показатели метрик для различных алгоритмов машинного обучения

	Trees.REPT	Trees. J48	Lazy. IBk	Rules. PART	Meta. Bagging
Acc (%)	79,1	79,2	77,6	78,9	80,2
TP (%)	31,8	31,3	30,9	30,9	31,9
TN (%)	43,9	44,1	43,3	44,6	44,3
FP (%)	6,8	6,5	7,2	6,1	6,4
FN (%)	9,8	10,2	10,9	10,9	9,5
Precision (Yes)	0,793	0,802	0,780	0,803	0,810
Precision (No)	0,800	0,795	0,781	0,785	0,807
Recall (Yes)	0,743	0,732	0,723	0,724	0,747
Recall (No)	0,861	0,864	0,849	0,873	0,868
F-Measure (Yes)	0,767	0,766	0,750	0,761	0,777
F-Measure (No)	0,829	0,828	0,814	0,827	0,837
ROC Area (Yes)	0,910	0,898	0,915	0,895	0,917
ROC Area (No)	0,911	0,908	0,925	0,904	0,927
PRC Area (Yes)	0,888	0,883	0,902	0,881	0,907
PRC Area (No)	0,913	0,911	0,932	0,904	0,930

Как видно из представленных результатов, все протестированные алгоритмы демонстрируют относительно высокую точность классификации, варьирующуюся от 77,6 до 80,2 %. Наилучшую точность (80,2 %) показывает ансамблевый метод Bagging, что объясняется его способностью

снижать дисперсию ошибок за счет агрегации множества моделей. Наименьшую точность демонстрирует метод k-ближайших соседей IBk (77,6 %), что может быть связано с чувствительностью этого метода к масштабированию данных и выбору параметра k.

На рисунке 1 представлено сравнение точности классификации для различных алгоритмов.

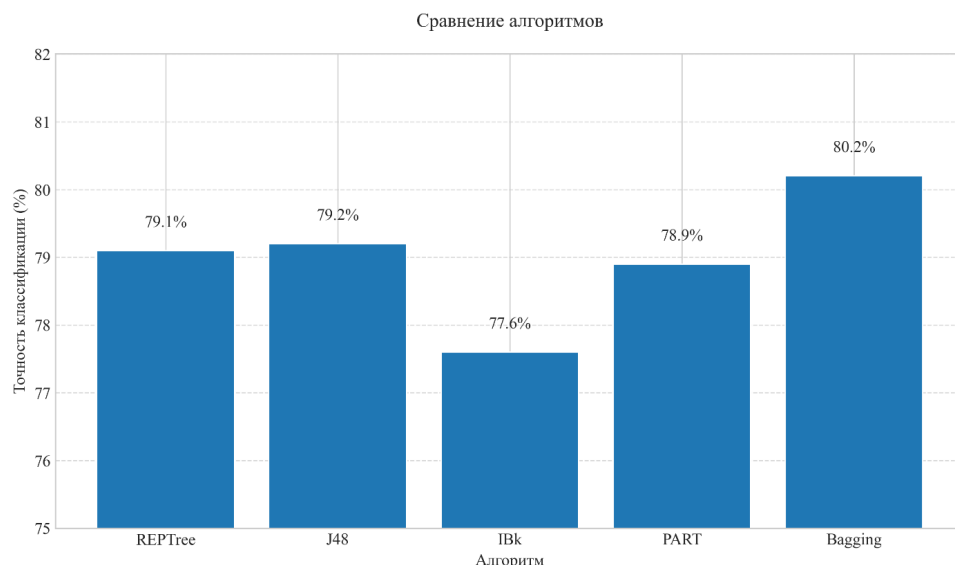


Рисунок 1 – Сравнение алгоритмов

Помимо общей точности классификации, важно проанализировать и другие метрики качества, особенно для класса «Явка» (Yes), который представляет наибольший интерес с практической точки зрения. На рисунке 2 представлено сравнение ключевых метрик для этого класса.

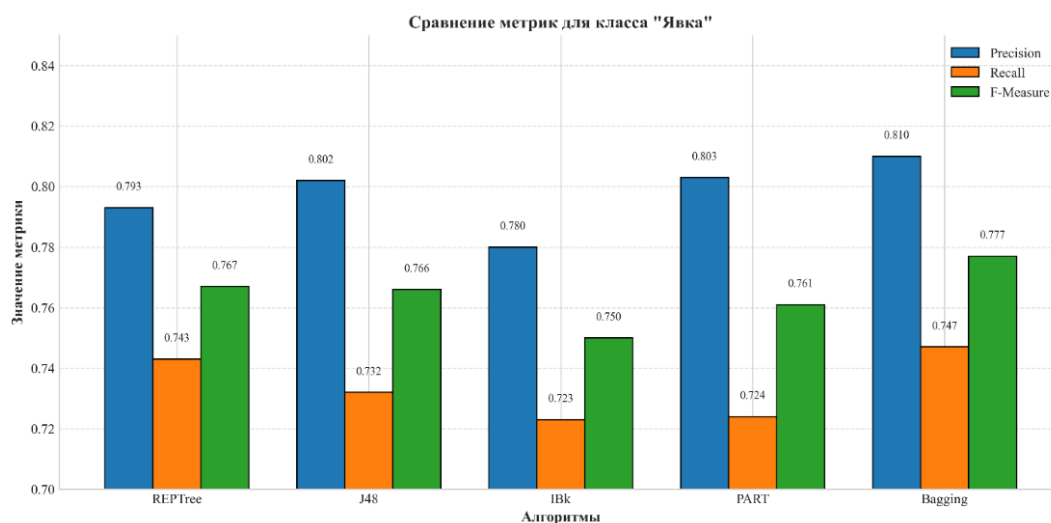


Рисунок 2 – Сравнение метрик для класса «Явка»

Метод Bagging демонстрирует наилучший баланс между точностью (Precision = 0,810) и полнотой (Recall = 0,747), что подтверждается высоким значением F-Measure (0,777). Это указывает на его устойчивость к ложным срабатываниям (FP) и пропущенным явкам (FN). Низкий Recall у IBk (0,723) свидетельствует о проблемах с выявлением реальных случаев явки.

Особенно значимым является баланс Bagging между точностью (Precision = 0,81) и полнотой (Recall = 0,747). Оптимальное сочетание этих параметров подтверждается значением F-Measure (0,777), что делает Bagging надежным инструментом для задач с требованием к сбалансированности ошибок.

Особый интерес представляет анализ ROC-кривых, показывающих способность моделей различать классы при различных порогах классификации. На рисунке 3 представлены ROC-кривые для всех протестированных алгоритмов.

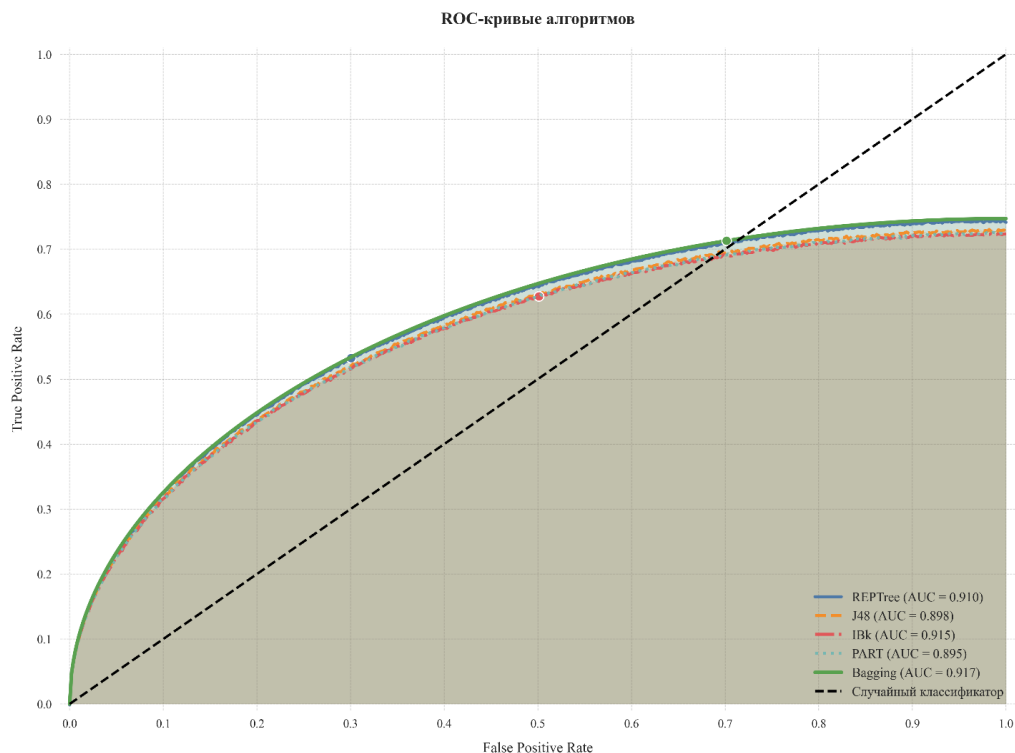


Рисунок 3 – ROC-кривые алгоритмов

ROC-кривые показывают, что методы Bagging (AUC = 0,917) и IBk (AUC = 0,915) обеспечивают наилучшее разделение классов для категории «Явка». Высокие значения площади под ROC-кривой (> 0,89) для всех алгоритмов подтверждают, что выбранные признаки являются информативными для задачи прогнозирования явки. Важно отметить, что метод Bagging сохраняет стабильность даже при низких значениях False Positive Rate, что критически важно для минимизации ложных ожиданий явки.

При рассмотрении метрик, более устойчивых к несбалансированности классов, таких как ROC Area и PRC Area (рис. 4), методы Bagging и IBk демонстрируют преимущество.

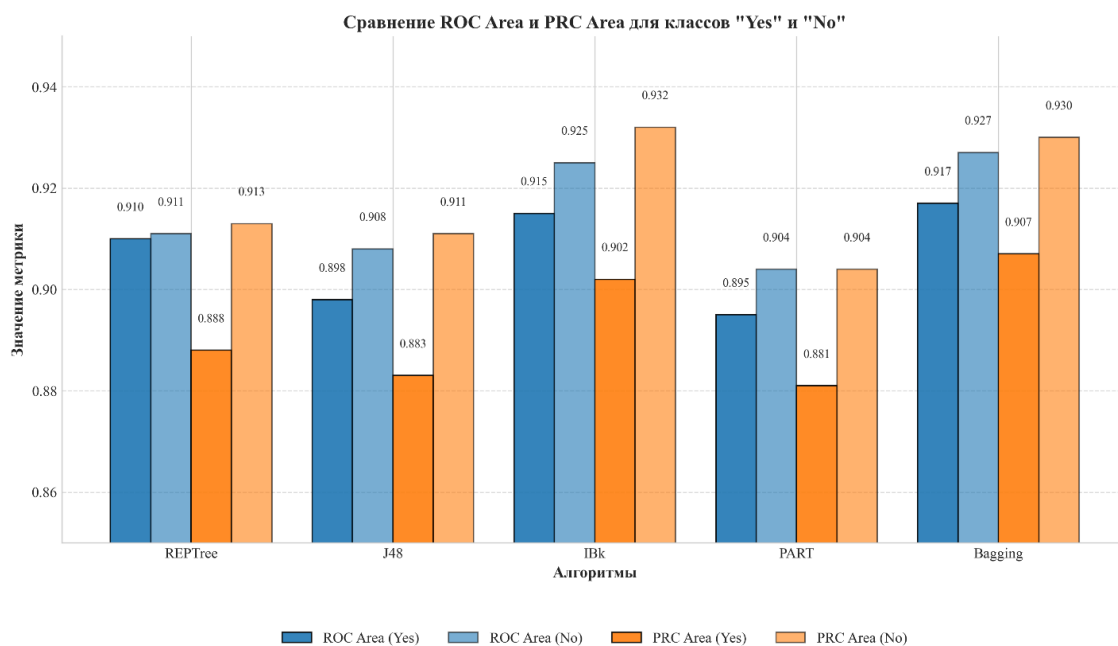


Рисунок 4 – Сравнение ROC Area и PRC Area для классов «Yes» и «No»

Bagging показывает стабильно высокие значения ROC Area (0,917 для «Yes» и 0,927 для «No»), подтверждая надежность в различении обоих классов. Интересно, что IBk, при более низкой общей точности (77,6 %), достигает высоких значений по ROC Area для класса «No» (0,925) и лидирует по PRC Area (0,932 для «No», 0,902 для «Yes»). Это указывает на его потенциальную эффективность в задачах, где критично точное выявление случаев неяви.

Примечательно, что все алгоритмы показывают значения ROC Area выше 0,89, что свидетельствует об их хорошей разделяющей способности. Минимальная разница между ROC и PRC Area (в среднем 0,02) подтверждает, что дисбаланс классов не оказывает существенного влияния на качество классификации.

РАСШИРЕННОЕ ЭКСПЕРИМЕНТАЛЬНОЕ СРАВНЕНИЕ МОДЕЛЕЙ

Для подтверждения полученных результатов были проведены дополнительные эксперименты в программе WEKA с увеличенным числом повторений (100) для минимизации случайных отклонений и анализом статистической значимости различий между алгоритмами при уровне доверия 0,05. Результаты представлены в таблице 2.

Таблица 2 – Результаты расширенного экспериментального сравнения (F-measure и Accuracy (%))

Алгоритм	F-measure	Accuracy (%)
trees.REPTree	0,84	91,57
trees.J48	0,83	91,31
rules.PART	0,82	90,92
meta.Bagging	0,84	91,85
lazy.IBk	0,81	90,43

В таблице 3 представлены результаты сравнения алгоритмов по площади под ROC-кривой и метрикам точности и полноты для класса «Явка» (IR_precision и IR_recall).

Таблица 3 – Результаты расширенного экспериментального сравнения (ROC Area, IR_precision, IR_recall)

Алгоритм	Area_under_ROC	IR_precision	IR_recall
trees.REPTree	0,98	0,83	0,85
trees.J48	0,97	0,82	0,84
rules.PART	0,97	0,83	0,82
meta.Bagging	0,98	0,83	0,85
lazy.IBk	0,98	0,81	0,82

Результаты расширенного экспериментального сравнения подтверждают преимущество ансамблевого метода Bagging, который демонстрирует наилучшие показатели по большинству метрик:

- наивысшая точность классификации (91,85 %);
- высокая F-мера (0,84, на уровне с REPTree);
- высокая площадь под ROC-кривой (0,98, на уровне с REPTree и IBk);
- высокая точность (0,83) и полнота (0,85) для класса «Явка».

Статистический анализ показал, что различия между Bagging и другими алгоритмами статистически значимы ($p < 0,05$) для большинства метрик, что подтверждает его превосходство. При этом деревья решений (REPTree и J48) демонстрируют результаты, близкие к Bagging, и могут рассматриваться как альтернативные варианты, особенно в случаях, когда важна интерпретируемость модели.

Сравнение с базовыми алгоритмами машинного обучения, такими как байесовские методы (BayesNet, NaiveBayes) и многослойный перцептрон (MultilayerPerceptron), показало значительное превосходство рассмотренных в основной части исследования алгоритмов. Например, точность классификации для BayesNet составила только 61,1 %, что почти на 20 % ниже, чем у метода Bagging.

ЗАКЛЮЧЕНИЕ

Проведенное исследование позволяет сделать несколько важных выводов относительно эффективности различных алгоритмов машинного обучения для задачи прогнозирования явки правонарушителей в суд.

Во-первых, все рассмотренные в основной части исследования алгоритмы (J48, REPTree, PART, Bagging, IBk) значительно превосходят базовые алгоритмы, такие как байесовские методы. Это подтверждает правильность выбора алгоритмов для решения поставленной задачи.

Во-вторых, ансамблевый метод Bagging демонстрирует наилучшие результаты по большинству метрик, включая общую точность классификации (80,2 % в первичном эксперименте и 91,85 % при дополнительной оптимизации). Это объясняется способностью ансамблевых методов снижать дисперсию ошибок и повышать устойчивость модели за счет комбинирования предсказаний нескольких базовых моделей.

В-третьих, деревья решений (J48 и REPTree) также показывают высокую эффективность, немного уступая методу Bagging по точности, но обладая при этом важным преимуществом – высокой интерпретируемостью. Это позволяет не только предсказывать явку, но и объяснять причины принятого решения, что может быть важно для практического применения в судебной системе.

В-четвертых, метод k-ближайших соседей (IBk) демонстрирует несколько более низкую общую точность, но при этом показывает высокие результаты по метрикам ROC Area и PRC Area для класса «No» (неявка). Это указывает на его потенциальную полезность в задачах, где особенно важно точное выявление случаев неявки правонарушителей.

Для различных категорий граждан могут быть разработаны персонализированные подходы к информированию о необходимости явки, учитывающие их индивидуальные особенности. Например, для граждан с высоким риском неявки могут быть использованы дополнительные каналы коммуникации (SMS-сообщения, электронная почта, звонки), а также более частые напоминания.

Ограничения данного исследования связаны с использованием относительно небольшого набора признаков для прогнозирования. В будущих исследованиях целесообразно расширить набор используемых признаков, включив информацию о социально-экономическом статусе правонарушителей, типе и тяжести правонарушения, географической удаленности от суда и других факторах, потенциально влияющих на вероятность явки.

В рамках данного исследования была разработана и проведен сравнительный анализ моделей прогнозирования явки правонарушителей в суд на основе методов машинного обучения. Исследование включало оценку эффективности пяти алгоритмов: дерева решений (J48, REPTree), алгоритм на основе правил (PART), ансамблевый метод (Bagging) и метод k-ближайших соседей (IBk).

Результаты исследования показали, что наилучшую эффективность для решения задачи прогнозирования явки правонарушителей в суд демонстрирует ансамблевый метод Bagging, обеспечивающий наивысшую точность классификации (80,2 % в первичном эксперименте и 91,85 % при дополнительной оптимизации) и сбалансированные показатели точности и полноты для обоих классов. Высокие значения площади под ROC-кривой ($> 0,91$) подтверждают надежность разработанной модели.

Деревья решений (J48 и REPTree) также показали высокую эффективность, предоставляя при этом интерпретируемые модели, способные объяснить причины принятых решений. Это делает их ценным инструментом для понимания факторов, влияющих на явку правонарушителей в суд.

Разработанная модель прогнозирования представляет собой важный шаг в направлении цифровизации и оптимизации судебной системы, способствуя повышению ее эффективности и рациональному использованию ресурсов. Для различных категорий граждан могут быть разработаны персонализированные подходы к информированию о необходимости явки, учитывающие их индивидуальные особенности и прогнозируемый риск неявки.

Прогнозирование в судебной системе действительно играет ключевую роль в ее цифровизации и оптимизации. Использование методов прогнозирования (на основе анализа больших данных и искусственного интеллекта) позволяет: оптимизировать нагрузку на судей, сокращать время рассмотрения дел, улучшать планирование заседаний. Также прогнозные модели помогают предсказывать затраты на судебные процессы, персонал и инфраструктуру. Предотвращать перегрузки – выявлять периоды пиковой нагрузки и заранее принимать меры. В то же время стоит учитывать определенные риски, такие как:

- этические вопросы – риск алгоритмической предвзятости (bias) в прогнозных моделях;
- защита данных – необходимость безопасного хранения и обработки конфиденциальной информации;
- человеческий фактор – прогнозы не должны заменять независимость судей, а лишь помогать в принятии решений.

Прогнозирование, основанное на данных и AI, действительно способно сделать судебную систему более эффективной, прозрачной и доступной. Однако его внедрение требует взвешенного подхода, учитывающего как технологические возможности, так и правовые, этические ограничения.

Список литературы

1. Михайлик, В. А. Анализ фактора явки правонарушителей в суд для построения модели бинарной классификации / В. А. Михайлик // Research Forum 2024 : сборник статей III Международной научно-практической конференции. – Петрозаводск : Международный центр научного партнерства «Новая Наука» (ИП Ивановская И.И.), 2024. – С. 96–107.

2. Магомедтагиров, М. М. Применение машинного обучения в социологии / М. М. Магомедтагиров, С. З. Айгубов, С. Р. Омарова // Региональные проблемы преобразования экономики. – 2019. – № 12 (110). – С. 233–239.
3. Богданов, М. Б. Возможности и ограничения цифровых следов и методов машинного обучения в социологии / М. Б. Богданов, И. Б. Смирнов // Мониторинг общественного мнения: экономические и социальные перемены. – 2021. – № 1 (161). – С. 304–328.
4. Quinlan, J. R. *C4.5: Programs for Machine Learning* / J. R. Quinlan. – 1993. – 296 p.
5. Cohen, W. W. Fast Effective Rule Induction / W. W. Cohen // *Machine Learning Proceedings*. – 1995. – P. 115–123. – URL: <https://www.sci-hub.ru/10.1016/B978-1-55860-377-6.50023-2?ysclid=m4e52wnyya24465361>.
6. Breiman, L. Bagging predictors / L. Breiman // *Machine Learning*. – 1996. – Vol. 24. – P. 123–140. – URL: <https://machine-learning.martinsewell.com/ensembles/bagging/Breiman1996.pdf>.
7. Angwin, J. Machine Bias – There’s Software Used across the Country to Predict Future Criminals. And It’s Biased against Blacks / J. Angwin, J. Larson, S. Mattu, L. Kirchner // *ProPublica, Online Edition*. – 2016. – URL: <https://www.scirp.org/reference/referencespapers?referenceid=3337609>.
8. Шахбанов, З. Метрики в машинном обучении: понимание, применение и интерпретация / З. Шахбанов 2024. – URL: <https://shakhbanov.org/metriki-v-mashinnom-obuchenii/>.

References

1. Mikhailik, V. A. Analysis of the factor of appearance of offenders in court for building a binary classification model. *Research Forum 2024 : collection of articles of the III International Scientific and Practical Conference*. Petrozavodsk: International Center for Scientific Partnership "New Science" (IP Ivanovskaya I.I.), 2024, pp. 96–107 (In Russ.).
2. Magomedtagirov, M. M., Ajgubov, S. Z., Omarova, S. R. Application of machine learning in sociology. *Regional Problems of Economic Transformation*, 2019, no. 12 (110), pp. 233–239 (In Russ.).
3. Bogdanov, M. B., Smirnov, I. B. Opportunities and limitations of digital footprints and machine learning methods in sociology. *Monitoring public opinion: economic and social changes*, 2021, no. 1 (161), pp. 304–328 (In Russ.).
4. Quinlan, J. R. *C4.5: Programs for Machine Learning*, 1993. 296 p.
5. Cohen, W. W. Fast Effective Rule Induction. *Machine Learning Proceedings*, 1995, pp. 115–123. Available at: <https://www.sci-hub.ru/10.1016/B978-1-55860-377-6.50023-2?ysclid=m4e52wnyya24465361>.
6. Breiman, L. Bagging predictors. *Machine Learning*, 1996, vol. 24, pp. 123–140. Available at: <https://machine-learning.martinsewell.com/ensembles/bagging/Breiman1996.pdf>.
7. Angwin, J., Larson, J., Mattu, S., Kirchner, L. Machine Bias – There’s Software Used across the Country to Predict Future Criminals. And It’s Biased against Blacks. *ProPublica, Online Edition*, 2016. Available at: <https://www.scirp.org/reference/referencespapers?referenceid=3337609>.
8. Shakhbanov Z. *Metrics in machine learning: understanding, application, and interpretation*, 2024. Available at: <https://shakhbanov.org/metriki-v-mashinnom-obuchenii/> (In Russ.).

Статья поступила в редакцию 19.05.2025; одобрена после рецензирования 17.07.2025; принята к публикации 15.09.2025.

The article was submitted 19.05.2025; approved after reviewing 17.07.2025; accepted for publication 15.09.2025.

УДК 510

ИСПОЛЬЗОВАНИЕ СЛУЧАЙНЫХ НЕЧЕТКИХ ПЕРЕМЕННЫХ ДЛЯ ОНЛАЙН-ОЦЕНКИ НЕОПРЕДЕЛЕННОСТИ ЦИФРОВЫХ ИЗМЕРИТЕЛЬНЫХ ПРИБОРОВ

Шаронов Павел Александрович, Саратовский государственный технический университет, 410054, Российская Федерация, г. Саратов, ул. Политехническая, 77,

аспирант, ORCID: 0009-0003-1568-242X., e-mail: stalker-scharonov@mail.ru

Львов Алексей Арленович, Саратовский государственный технический университет, 410054 Российская Федерация, г. Саратов, ул. Политехническая, 77,

доктор технических наук, профессор ORCID: 0000-0003-4270-7867, e-mail: alvova@mail.ru

Статья посвящена проблеме оперативной оценки неопределенности в цифровых измерительных приборах. Традиционный вероятностный подход для сложных алгоритмов цифровой обработки сигналов часто неприменим в реальном времени и не учитывает систематические погрешности. В качестве решения предлагается метод на основе случайных нечетких переменных, который более универсально учитывает все типы неопределенностей. Описаны принципы представления данных в формате случайных нечетких переменных и приведены результаты успешного экспериментального применения метода для измерения действующего значения и гармоник гармонических сигналов, подтвердившие его точность и вычислительную эффективность для онлайн-реализации.

Ключевые слова: измерительные приборы, основанные на цифровой обработке сигналов, случайные переменные, оценка неопределенности

USING RANDOM FUZZY VARIABLES FOR ONLINE UNCERTAINTY ASSESSMENT OF DIGITAL MEASURING INSTRUMENTS

Sharonov Pavel A., Saratov State Technical University, 77 Politechnicheskaya St., Saratov, 410054, Russian Federation,

postgraduate student, ORCID: 0009-0003-1568-242X., e-mail: stalker-scharonov@mail.ru

Lvov Alexey A., Saratov State Technical University, 77 Politechnicheskaya St., Saratov, 410054, Russian Federation,

Doct. Sci. (Engineering), Professor ORCID: 0000-0003-4270-7867, e-mail: alvova@mail.ru

The article addresses the problem of real-time uncertainty evaluation in digital measuring instruments with DSP. The traditional probabilistic approach is often unsuitable for complex DSP algorithms in real-time applications and does not account for systematic errors. As a solution, a method based on random-fuzzy variables is proposed, which more comprehensively combines all types of uncertainties. The principles of data representation in the random-fuzzy variables format are described, and the results of successful experimental application of the method for measuring root mean square values and harmonics are presented, confirming its accuracy and computational efficiency for online implementation.

Keywords: measuring instruments based on DSP, random variables, uncertainty estimation

ВВЕДЕНИЕ

Современные измерительные приборы, построенные на базе цифровой обработки сигналов (ЦОС), с метрологической точкой зрения выполняют совместные измерения, которые зачастую проводятся косвенными методами [1–3]. Для процесса измерения, проводимого приборами с ЦОС, характерной чертой является тот факт, что окончательный результат измерения формируется с помощью процедуры алгоритмической обработки некоторой последовательности дискретных отсчетов входных сигналов. Таким образом, эти входные отсчеты являются первичными данными – результатом прямых измерений, которые выступают как основа для последующих вычислений, а встроенное в цифровое устройство программное обеспечение устанавливает функциональную связь между этими исходными сигналами и искомой величиной.

В соответствии с международными и отечественными стандартами, а также руководством Международной электротехнической комиссии МЭК (МЭК, *International Electrotechnical Commission*, IEC) и принципами метрологической политики [1–5], результат каждого измерения должен сопровождаться оценкой его неопределенности. Результирующую (итоговую) стандартную неопределенность определяют посредством сочетания признаков и собственных неопределенностей каждого входного отсчета, получаемого по цепочке от первичных датчиков, преобразователей сигналов и аналого-цифровых преобразователей (АЦП). Однако практическая реализация данных рекомендаций для сложных алгоритмов ЦОС-приборов (используемых для решения сложных измерительных задач, например, при контроле качества электроэнергии, мониторинге экологической обстановки и здоровья населения, обеспечения промышленной безопасности) встречает дополнительные препятствия [6–8] из-за высокой вычислительной сложности. Это часто исключает возможность

оперативного расчета (в режиме реального времени) возникающей при измерениях неопределенности. Такая попытка оценки была предпринята в работе [9].

По указанным причинам очень актуальной встала проблема разработки ЦОС-измерителей различных физических величин, способных самостоятельно, без участия оператора, в онлайн-режиме выдавать информацию о неопределенности получаемых результатов, при условии наличия априорной характеристики входных отсчетов. Это освобождает пользователя от сложных расчетов и снижает риски, связанные с нормативными требованиями. Одним из путей решения данной проблемы является применение альтернативных методик, отличных от предложенных в руководствах МЭК и национальных стандартах [1–5]. Эти официальные документы трактуют неопределенность как стохастическую переменную, что с позиций строгой статистики справедливо лишь для результатов, подверженных исключительно случайным воздействиям. В реальных же условиях, особенно вне лабораторий, значительное влияние могут оказывать систематические погрешности, не поддающиеся идентификации, интерпретация которых вероятностными методами может привести к некорректной оценке.

Авторы работ [10–12] выдвинули альтернативный обобщенный подход к исследованию неопределенностей измерений, который выбрал за основу теорию доказательств, предложенную в математических работах [13–15]. Суть нового метода состоит в описании результата измерения и неопределенности, связанной с ним, с помощью случайных нечетких переменных (СНП, или *Random-Fuzzy Variables*, RFV) [10, 12]. Данная методология обеспечивает более полную и адекватную оценку измерительной неопределенности по сравнению с вероятностным подходом. Важным практическим преимуществом является ее вычислительная эффективность, что открывает возможность для интеграции непосредственно в измерительные приборы при выполнении оперативных расчетов в онлайн-режиме. Настоящая статья содержит краткое описание процедур представления неопределенности через СНП (с изложением математических основ можно ознакомиться в [10, 12, 16]), а также демонстрирует практический пример оценки неопределенности в онлайн-режиме на реальных экспериментальных данных.

ПРЕДСТАВЛЕНИЕ ИЗМЕРИТЕЛЬНОЙ НЕОПРЕДЕЛЕННОСТИ ЧЕРЕЗ СЛУЧАЙНЫЕ НЕЧЕТКИЕ ПЕРЕМЕННЫЕ

В рамках теории нечетких множеств [17] утверждается, что нечеткая переменная A в универсальном множестве X может характеризоваться функцией $\mu_A(\alpha)$:

$$\mu_A(\alpha): X \rightarrow [0, 1].$$

Эта функция определяет соответствие между значениями $\mu_A(\alpha)$, расположенными в интервале $0 \leq \mu_A(\alpha) \leq 1$, и элементом $\alpha \in X$ и названа функцией принадлежности (ФП). Выпуклая ФП $\mu_A(\alpha)$ масштабируется и «нормируется так, чтобы всегда максимальное значение этой функции устанавливалось равным единице» [17].

Далее вводится понятие α -сечения (или α -среза) для нечеткой переменной A , для чего выбирается параметр α , удовлетворяющий условию $0 \leq \alpha \leq 1$, который задается как:

$$A_\alpha = \{a \in X \mid \mu_A(\alpha) \geq \alpha\}, \quad (1)$$

«где каждый α -срез является интервалом неопределенности, локализирующим переменную с заданным уровнем значимости α » [11, 12, 16].

Тогда новый способ задания нечетких переменных состоит в объединении всех α -срезов. Кроме того, α -срезы характеризуются свойством вложенности – они учитывают классификацию вложенных множеств, что обеспечивает совместимость нечеткой математики и интервальных методов с общей теорией доказательств [11, 12, 16].

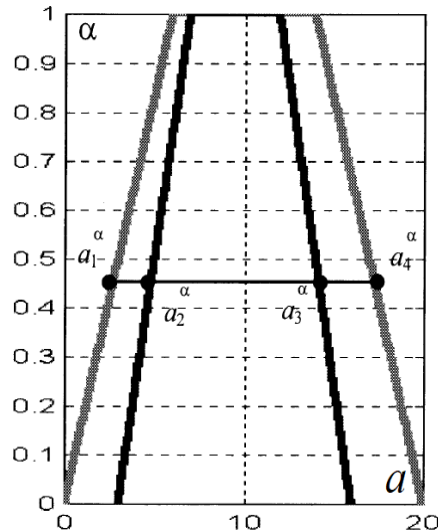
СНП формализуется через α -срезы, где каждый α -срез задается четверкой чисел:

$$A_\alpha = [a_1^\alpha, a_2^\alpha, a_3^\alpha, a_4^\alpha], \quad (2)$$

где для любого α справедлива цепочка неравенств $a_1^\alpha \leq a_2^\alpha \leq a_3^\alpha \leq a_4^\alpha$.

Иначе говоря, интервал $[a_1^\alpha, a_4^\alpha]$ считается интервалом неопределенности с уровнем достоверности (доверительной вероятностью), равным $1 - \alpha$. В данном интервале (рис. 1) можно выделить три области, разделяемых границами a_2^α и a_3^α , которые зависят от распределения возможных результатов.

Относительно центральной области $[a_2^\alpha, a_3^\alpha]$ отсутствует информация о характере распределения возможных результатов a в ней ($a_2^\alpha \leq a \leq a_3^\alpha$). Для боковых областей $[a_1^\alpha, a_2^\alpha]$ и $[a_3^\alpha, a_4^\alpha]$ получающиеся значения a ($a_1^\alpha \leq a < a_2^\alpha$ и $a_3^\alpha < a \leq a_4^\alpha$) полагаются случайными результатами, подчиняющимися нормальному закону распределения [11, 18].

Рисунок 1 – Пример формирования α -среза для СНП

Конкретно, считается, что на участке $[a_1^\alpha, a_2^\alpha]$ значения a подчиняются закону распределения, совпадающему с половиной нормальной плотности вероятности, находящейся слева от ее среднего значения, при этом максимум совпадает с точкой a_2^α , среднеквадратическое значение этой плотности σ выбирается из условия $a_1^\alpha = a_2^\alpha - 3\sigma$. По аналогии на участке $[a_3^\alpha, a_4^\alpha]$ значения a подчиняются закону распределения, соответствующему правой части нормальной плотности, где ее максимум находится в a_3^α , а $a_4^\alpha = a_3^\alpha + 3\sigma$.

Исследования, описанные в [10–12], доказали возможность применения СНП для характеристики плотностей вероятности случайных измеряемых физических величин. Действительно, для произвольного возможного уровня достоверности $1 - \alpha$ обычно полагают, что случайные воздействия на процесс измерения влияют только на случайные изменения измеряемых значений на боковых участках $[a_1^\alpha, a_2^\alpha]$ и $[a_3^\alpha, a_4^\alpha]$, которые имеют нормальную плотность вероятности. Напротив, воздействия детерминированного типа (неслучайные) являются источником изменения результатов измерений во внутреннем участке $[a_2^\alpha, a_3^\alpha]$, при этом характер распределения их на этом подынтервале неизвестен [11, 12]. При отсутствии неслучайных воздействий учитываются исключительно стохастические эффекты $a_2^\alpha = a_3^\alpha$; в обратном случае при отсутствии случайных эффектов $a_1^\alpha = a_2^\alpha$ и $a_3^\alpha = a_4^\alpha$.

При анализе ЦОС-измерителей «каждый входной отсчет вместе с его неопределенностью, обусловленной влиянием входных цепей и АЦП, может быть представлен через СНП» [10, 12]. После чего функция:

$$y = f(x_1, x_2, \dots, x_n), \quad (3)$$

задающая зависимость выходной переменной y (результата измерения) с прямыми отсчетами x_i ($1 \leq i \leq n$), может быть заменена аналогичной зависимостью между СНП:

$$Y = f(X_1, X_2, \dots, X_n). \quad (4)$$

Соотношение (4) «является числовой характеристикой искомого результата измерения совместно с интервалами неопределенности для любых уровней доверительной вероятности $1 - \alpha$, начиная с СНП, описывающих каждый отдельный отсчет входного сигнала и связанных с ним доверительных интервалов» [10–12].

В соответствии с рекомендациями МЭК, международных и национальных стандартов [1–5], неопределенность требуется характеризовать через доверительные интервалы. Ввиду сказанного, трактовка результата измерения в форме СНП полностью согласуется с этими требованиями. Более того, в этом случае определяются все доверительные интервалы, относящиеся ко всем возможным доверительным вероятностям [11]. Поэтому предлагаемый подход обладает большей информативностью для исследователя измерительной информации.

После выбора математического аппарата, требуемого для работы с СНП [11, 12], для вычисления измеряемой цифровым прибором величины можно пользоваться формулой (4) вместо выражения (3). В этом случае выходная измеряемая величина задается в виде СНП, описывающей результаты измерения и ассоциированные с ним интервалы достоверности, дающие в совокупности значение неопределенности измерения. Однако предварительно требуется определение СНП для всех входных отсчетов цифрового измерительного прибора.

ФОРМИРОВАНИЕ СЛУЧАЙНЫХ НЕЧЕТКИХ ПЕРЕМЕННЫХ ДЛЯ ПРЕДСТАВЛЕНИЯ РЕЗУЛЬТАТОВ ИЗМЕРЕНИЙ

Построение случайных нечетких функций

Для определения метрологических характеристик входных цепей и аналого-цифровых преобразователей (АЦП) измерительной цифровой аппаратуры в рамках концепции СНП необходимо в максимальной степени использовать всю доступную информацию. Данная информация может быть получена из документации производителя для случаев неопределенности типа В в соответствии с руководящими документами МЭК-ИСО и национальными стандартами [1, 4], либо с помощью экспериментальных исследований, как рекомендуют документы при оценке неопределенности первого типа. Во всех случаях необходимо преобразовать полученные экспериментальные данные в формат СНП для последующего применения описанного выше математического аппарата, что необходимо при анализе распространения неопределенностей в процессе обработки вычислительной информации, выполняемой согласно заданному алгоритму. Помимо этого, имеющиеся данные о нормируемых свойствах АЦП и входных каскадов цифровых приборов тоже требуется выразить через СНП.

При исследовании неопределенности типа В производитель или калибровочная лаборатория задают диапазон изменения измеряемой величины, внутри которого гарантированно находится ее истинное значение. В этом диапазоне плотность вероятностей полученных результатов считается распределенной по равномерному закону, так как отсутствуют какие-либо сведения, свидетельствующие о целесообразности выбора другого определенного закона распределения этих результатов.

Равномерное вероятностное распределение характеризует состояние полной неосведомленности об исследуемой физической величине, не считая интервала, в котором данная величина гарантированно находится. Поэтому логично, что это распределение может быть трансформировано в распределение возможностей, тоже соответствующее состоянию полной неосведомленности об объекте, когда трансформируемому распределению присваивается единичное значение возможности [11, 12, 16]. Тогда распределение возможностей задается с помощью нечеткой переменной, имеющей ФП всюду на всем рассматриваемом интервале нахождения равномерно распределенной физической величины, равной 1. Для сформированной таким образом СНП далее проводится задание соответствующих границ $a_1^\alpha = a_2^\alpha$ и $a_3^\alpha = a_4^\alpha$.

При анализе характеристик цифровой измерительной аппаратуры, основанных на экспериментальных данных, наличие которых обеспечивается путем получения результатов многократных повторяющихся измерений некоторых калибровочных объектов с известными параметрами, исследуемыми с помощью данной аппаратуры. Распределение результатов таких повторных измерений параметров калибровочных объектов, как правило, представляется гистограммами относительных частот попадания величин измеряемых параметров в некоторые специальные подынтервалы. При достаточном уровне измерительных данных и достаточной «малости» подынтервалов становится возможной интерполяция гистограмм, чтобы получить приближенную функцию плотности вероятности. Эта функция, в свою очередь, преобразуется в ФП, которая выступает в роли функции плотности возможностей, иными словами – в роли внешней ФП СНП.

Существует ряд подходов, позволяющих выполнить трансформацию «вероятность – возможность» и описанных в научной литературе. Эти методы варьируются от простого масштабирования шкалы отношений, использованного в работе [19], до значительно более усложненных преобразований и последовательных процедур, в основе которых лежат различные известные методики [16, 20, 21].

Авторы считают, что предложенные решения не полностью соответствуют концепции СНП, излагаемой в настоящей работе. Простые решения не всегда дают верные результаты на практике, а сложные – зачастую слишком трудно реализуемы в конкретных условиях эксперимента. Поэтому в данной работе предлагается альтернативное решение, разработанное с учетом следующих обязательных условий.

При заданной нечеткой переменной мера достоверности нахождения значения x в границах интервала $[x_1, x_2]$, определяемого соответствующим α -срезом, определяется в теории возможностей величиной $1 - \alpha$, где α представляет собой уровень значимости рассматриваемого α -среза.

Но в классическом случае, когда задана плотность распределения вероятностей $p(x)$ случайной величины $x \in X$, несложно определить вероятность $P_{x_1 \leq x \leq x_2}$ нахождения значения x в границах отрезка $[x_1, x_2]$ из известного в теории вероятностей соотношения [18]:

$$P_{x_1 \leq x \leq x_2} = \int_{x_1}^{x_2} p(x) dx. \quad (5)$$

С учетом изложенных выше условий СНП может формироваться из вероятностного распределения экспериментальных результатов следующим способом.

Находится максимальное x_p , при котором функция плотности вероятностей достигает наибольшей величины. Считается, что для этого x_p ФП формируемой СНП принимает максимальное значение, равное единице. Далее производится поиск границ распределения x_i и x_r ($x_i < x_p < x_r$). В этих точках,

расположенных с обеих сторон от x_p , функция плотности достигает нулевых значений. В предельном случае, когда плотность вероятности задается бесконечной функцией, спадающей к нулю на своих концах (например, нормальная плотность распределения), точки x_i и x_r являются концами отрезка $[x_i, x_r]$, вероятность нахождения внутри которого для случайной величины x равна $P_{x_i \leq x \leq x_r} = 0,99728$ (при нормальном распределении x это соответствует интервалу $[-3\sigma, 3\sigma]$ относительно математического ожидания, σ – стандартное отклонение x). Отрезки $[x_i, x_p]$ и $[x_p, x_r]$ делятся на одинаковое число участков с границами $x_i, x_{i_1}, x_{i_2}, \dots, x_p$ и $x_p, \dots, x_{r_2}, x_{r_1}, x_r$, как показано на рисунке 2, где обозначены только x_{i_1} и x_{r_1} .

После этого для каждого выбранного отрезка $[x_{i_j}, x_{r_j}]$ рассчитываются значения вероятности P_j из соотношения (5) $P_j = \int_{x_{i_j}}^{x_{r_j}} p(x) dx$; и, наконец, для него по определению, как для α -среза формируемой ФП, задается значение уровня достоверности, равное $\alpha_j = 1 - P_j$. СНП, построенная таким способом, обладает свойством, что $\alpha_2^g = \alpha_3^g$. Сама методика формирования СНП представлена на рисунке 2.

В ситуациях, когда доступная метрологическая информация частично соответствует расчету неопределенности определения В типа (которая с учетом условий, описанных ранее, трансформируется в нечеткую ФП μ_1 прямоугольного вида), а частично соответствует оцениванию неопределенности А типа (из упомянутых условий следует, что в этом случае переходит в СНП с внешней ФП μ_2 и внутренней нулевой ФП). Итоговая СНП получается с помощью корректного объединения двух описанных методик получения внутренней и внешней ФП.




Рисунок 2 – Преобразование функции плотности вероятности в соответствующую ФП СНП

Эффективная методика совместной оценки неопределенностей типов А и В заключается в корректном «внедрении» ФП μ_1 внутрь μ_2 . Это реализуется с помощью определения общих α -срезов для одинакового уровня достоверности α у обеих ФП μ_1 и μ_2 , конкретно, $[x_{L_1}^\alpha, x_{R_1}^\alpha]$ и $[x_{L_2}^\alpha, x_{R_2}^\alpha]$ соответственно.

Интервал $[x_{L_2}^\alpha, x_{R_2}^\alpha]$ разбивается на два подынтервала $[x_{L_2}^\alpha, x_p]$ и $[x_p, x_{R_2}^\alpha]$, в которых x_p задает максимум ФП μ_2 , заданной ранее. α -срез $X_\alpha = [x_a^\alpha, x_b^\alpha, x_c^\alpha, x_d^\alpha]$, соответствующих итоговой СНП, рассчитывается из соотношений:

$$\begin{cases} x_b^\alpha = x_{L_1}^\alpha; \\ x_c^\alpha = x_{R_1}^\alpha; \\ x_a^\alpha = x_b^\alpha - (x_p - x_{L_2}^\alpha); \\ x_d^\alpha = x_c^\alpha + (x_{L_2}^\alpha - x_p). \end{cases}$$

Характеристика АЦП с помощью СНП

Для проверки правомерности предлагаемой методики формирования СНП было проведено исследование 12-битного модуля АЦП с нижним периодом дискретизации 20 мкс, выполненного в виде отдельной платы в персональном компьютере. По сути, выбранный модуль является входом ЦОС-вольтметра, взятого для экспериментальных исследований, целью которых было подтвердить эффективность применения СНП в качестве аппарата для описания неопределенностей измерения. Для проверки методики с помощью платы АЦП дополнительно использовался калибратор Fluke

5500A (фирма изготовитель *Fluke Corporation*, США), выполняющий функцию источника эталонного измеряемого напряжения, которое подавалось на модуль АЦП, простым методом, изложенным в работе [12]. Безусловно, возможно применение более сложных и ресурсоемких методов питания сигналами напряжения модуля АЦП [22–26], но они не использовались, поскольку цель предлагаемой статьи заключается исключительно в описании и верификации корректности описанной выше методики для оценки неопределенности измерений параметров прибора, использующего ЦОС, в онлайн-режиме, а не в комплексном изучении характеристик и точности АЦП.

Исследование модуля АЦП проводилось с помощью автоматизированной измерительной системы [12], позволяющей экспериментально получить кривую преобразования прибора во всем его динамическом диапазоне. В процессе калибровки был исследован весь диапазон входного напряжения от -10 до $+10$ вольт с шагом в 1 милливольт. Это позволило оценить величину порога шага квантования (минимальное изменение входного сигнала, которое АЦП способен различить) примерно в 0,25 младшего значащего бита в двоичном представлении результата измерения. Для каждой точки калибровки (каждого значения входного напряжения) было получено по 10 000 отсчетов напряжения [12]. Анализ полученных данных показал, что нелинейность АЦП (отклонение реальной характеристики преобразования от идеальной линейной зависимости) значительно меньше, чем погрешность, обусловленная самим процессом квантования (размер шага квантования) во всем исследованном диапазоне входных сигналов [12]. Другими словами, основным источником погрешности АЦП является дискретный характер преобразования, а не неточности в его электронной схеме. В результате анализа полученных измерительных данных было установлено, что погрешность нелинейности АЦП значительно меньше погрешности квантования во всем диапазоне возможных входных сигналов [12]. По этой причине основными источниками неопределенности модуля АЦП в процессе осуществления преобразования в цифровую форму входных аналоговых сигналов авторы ограничились учетом индивидуальных неопределенностей трех влияющих параметров, а именно, коэффициента передачи усилителя, нестабильности установки нуля и задания шага квантования. Рисунок 3 иллюстрирует СНП соответственно коэффициента передачи усилителя G , смещения нуля U_{off} из-за нестабильности его установки и выбора шага квантования АЦП Δ , полученные в работе авторов [12] с помощью обработки реальных экспериментальных данных по методике из раздела 2.1 настоящей работы, а также спецификаций прибора Fluke 5500A.




Рисунок 3 – ФП $\mu(x)$ в единицах СНП: для коэффициента усиления (а), смещение нуля (б), выбора шага квантования (в)

Представление СНП

Ввиду влияния на процесс измерения множества случайных факторов и детерминированных воздействий процедура учета их совместного влияния может быть достаточно сложной с вычислительной точки зрения. Следовательно, необходимо определить действенную методику описания СНП. Эту методику надо выбирать из условий обеспечения удобного хранения измерительной информации с минимальными затратами ресурсов памяти вычислителя. Помимо этого, должна обеспечиваться и относительная простота используемых математических операций обработки случайных измеряемых величин, чтобы можно было использовать встроенный в цифровой измерительный прибор микропроцессор без применения дополнительных вычислительных мощностей. В предлагаемом подходе все процедуры построения СНП описываются с помощью понятия α -среза, для чего используются специальные математические операции. Более того, эти операции применяются для каждого α -среза самих СНП [11, 12]. Поэтому логично описывать формируемые СНП также в терминах понятия α -среза. Как следует из определения α -среза (1), (2), он задается четырьмя числовыми параметрами (рис. 1). В этом случае очень удобно компактно представлять нечеткое множество в виде матрицы, содержащей четыре столбца, каждый из которых содержит набор значений конкретного параметра a_j^α ($j = \overline{1,4}$) из (2), для всех задаваемых исследователем значений уровней значимости α . Следовательно, число строк в матрице равно числу выбранных уровней α . Увеличение

количества строк ведет к повышению точности представления нечеткого множества. Стоит отметить, что с ростом числа входных строк, описывающих нечеткое множество, пропорционально увеличиваются как объем необходимой памяти, так и вычислительные затраты при цифровой обработке сигналов. Исследования, представляемые в предлагаемой работе, демонстрируют, что следует установить разумный баланс между точностью задания нечетких множеств и сложностью их представления путем надлежащего выбора числа α -срезов (значений уровня значимости). По мнению авторов, для абсолютного большинства измерительных приложений можно ограничиться числом строк, равным 101 (учитывается 101 α -срез). Тогда размер матрицы, задающей СНП, становится 101×4 . В ней в первую строку помещаются значения четырех α -срезов $a_1^\alpha, a_2^\alpha, a_3^\alpha, a_4^\alpha$, соответствующих уровню значимости $\alpha = 0$; во вторую строку – уровню значимости $\alpha = 0,01$ и т. д. с шагом 0,01 по α . В последней строке с номером 101 будут значения для $\alpha = 1,0$. В каждой строке первый столбец содержит a_1^α , второй – a_2^α , третий – a_3^α и четвертый – a_4^α . В результате, операции, проводимые для СНП, становятся матричными, для обработки которых наиболее подходящим является среда MATLAB.

ОПЕРАТИВНАЯ ОЦЕНКА НЕОПРЕДЕЛЕННОСТИ В ПРОЦЕССЕ ИЗМЕРЕНИЙ

После проведения метрологической характеристики входных цепей и АЦП измерительного устройства с применением цифровых методов обработки сигналов в рамках концепции СНП согласно описанной выше процедуре становится возможным выполнение измерительных операций посредством специализированного алгоритма. Данный метод обрабатывает каждую полученную выборку и формирует результаты измерений совместно с соответствующей оценкой неопределенности в формате СНП.

После определения СНП для параметров G , U_{off} и Δ , полученным цифровым измерительным прибором на базе ЦОС, проверяем СНП S_k истинного значения входного сигнала согласно соотношению:

$$S_k = \frac{s_k - \Delta}{G} - U_{off}, \quad (k = 1, 2, \dots, N). \quad (6)$$

Для реализации базовых математических операций с СНП была создана специальная библиотека функций в программной среде MATLAB. С целью упрощения описания процедур верификации предлагаемых методов оперативного измерения неопределенностей был создан модуль понятного пользовательского интерфейса. В качестве входного АЦП для созданного программного обеспечения была применена идентичная плата АЦП, которая использовалась при экспериментальном применении, рассмотренном в предыдущем разделе.

На начальном этапе был создан базовый алгоритм определения действующего значения (ДЗ) сигнала, которое, как известно, совпадает с его среднеквадратичным значением. Эти результаты, вычисляемые по предлагаемой методике, сопоставляются с ДЗ, считанным с панели управления калибратором, включая соответствующий доверительный интервал. На следующем этапе в среде MATLAB была реализована методика анализа гармонического состава сигнала, основанная на подходе из работы [27].

Методика определения эффективного значения сигнала

Первичная экспериментальная проверка проводилась с использованием сигналов синусоидального напряжения, частота которых была 50 Гц. Отсчеты сигналов подвергались процедуре обработке с помощью алгоритмов, реализующих разработанную методику. Для проверки корректности методики построения СНП на АЦП калибратором Fluke 5500A подавались входные сигналы различных амплитуд, соответствующих динамическому диапазону.

Далее каждый отсчет сигнала s_k преобразовывался в соответствующий отсчет S_k посредством выражения (6). Затем на основе выборки преобразованных значений S_k вычислялось ДЗ входного напряжения согласно формуле:

$$S = \frac{1}{N} \sqrt{\sum_{k=1}^N S_k^2}, \quad (7)$$

где N – это общее количество отсчетов в выборке.

На рисунке 4 приведены результаты расчетов на основе выражения (7) для гармонического сигнала, ДЗ которого было равно 6,9 В. Можно отметить, что между значениями ДЗ, задаваемых калибратором, и СНП, формируемыми на основе предложенной в работе методики, наблюдалось очень малое расхождение результатов. Этот факт был зафиксирован и для других протестированных входных сигналов калибратора, представленных в таблице 1.




Рисунок 4 – Функция принадлежности, построенная по предложенной методике, для действующего значения сигнала 6,9 В. Стрелкой показано значение сигнала, заданное калибратором Fluke 5500A

В таблице данных первый столбец содержит доверительные интервалы, обеспечиваемые эталонным значением калибратора для каждого входного сигнала. Четвертый столбец представляет собой доверительные интервалы между границами СНП (внутренний доверительный интервал), тогда как пятый столбец показывает расширенные интервалы между значениями сигнала в точках пересечения наклонных границ с осью абсцисс (внешний доверительный интервал). Полуширины внутренних и внешних доверительных интервалов для трех различных результатов α ($\alpha = 0,0; 0,5$ и $1,0$). Анализ полученных СНП позволяет сделать вывод, что результаты, представленные с помощью СНП, всегда содержат внутри себя значение напряжения калибратора вместе с доверенными интервалами.

Для сравнения возможностей всех упомянутых подходов, включая методики, основанные на рекомендациях МЭК и стандартов [1–5], в качестве критерия сравнения была выбрана суммарная стандартная неопределенность, рассчитываемая на основе преобразованных отсчетов в соответствии с выражением (7) S_k .

Таблица 1 – Сравнение фактических значений сигнала, заданного калибратором, с включенными значениями ДЗ и доверительными интервалами СНП

ДЗ, установленное на калибраторе	Измеренное ДЗ	α	Внутренний доверительный интервал	Внешний доверительный интервал
1,141400 В \pm 0,14 мВ	1,41329 В	0,0	{ -2,26 мВ +2,26 мВ	{ -2,81 мВ +2,46 мВ
		0,5	{ -2,17 мВ +2,17 мВ	{ -2,41 мВ +2,26 мВ
		1,0	{ -2,08 мВ +2,08 мВ	{ -2,08 мВ +2,08 мВ
2,83000 В \pm 0,14 мВ	2,82915 В	0,0	{ -2,27 мВ +2,27 мВ	{ -3,09 мВ +2,65 мВ
		0,5	{ -2,18 мВ +2,18 мВ	{ -2,541 мВ +2,35 мВ
		1,0	{ -2,09 мВ +2,09 мВ	{ -2,09 мВ +2,09 мВ
4,2400 В \pm 0,40 мВ	4,23905 В	0,0	{ -2,28 мВ +2,28 мВ	{ -3,35 мВ +2,88 мВ
		0,5	{ -2,19 мВ +2,19 мВ	{ -2,66 мВ +2,45 мВ
		1,0	{ -2,10 мВ +2,10 мВ	{ -2,10 мВ +2,10 мВ
5,6600 В \pm 1,30 мВ	5,65911 В	0,0	{ -2,29 мВ +2,29 мВ	{ -3,64 мВ +3,17 мВ
		0,5	{ -2,20 мВ +2,20 мВ	{ -2,80 мВ +2,58 мВ
		1,0	{ -2,11 мВ +2,11 мВ	{ -2,11 мВ +2,11 мВ
6,9000 В \pm 1,30 мВ	6,8988 В	0,0	{ -2,30 мВ +2,30 мВ	{ -3,91 мВ +3,45 мВ
		0,5	{ -2,21 мВ +2,21 мВ	{ -2,92 мВ +2,71 мВ
		1,0	{ -2,12 мВ +2,12 мВ	{ -2,12 мВ +2,12 мВ

Процедура обработки заключалась в следующем. Для каждого из учитываемых факторов: коэффициента передачи усилителя G , смещения U_{off} и выбора шага квантования Δ АЦП по экспериментальным данным и спецификации прибора Fluke 5500A оценивались их индивидуальные стандартные неопределенности. Далее эти неопределенности пересчитывались в стандартные неопределенности величин S_k на основе соотношения (6). Эти полученные стандартные неопределенности параметров S_k обрабатывались с помощью формулы (7), что дало возможность рассчитать суммарную стандартную неопределенность.

Однако для корректного суммирования нелинейных величин в выражении (7) необходимо учитывать коэффициенты корреляции между исходными случайными отсчетами s_k из (6). Поскольку реальные значения этих коэффициентов неизвестны, были рассмотрены два крайних случая:

- корреляция между коэффициентом усиления, смещением и квантованием АЦП, включая все случайные отсчеты s_k , полностью отсутствует (все коэффициенты корреляции равны 0);
- корреляция между выбором шага квантования АЦП со всеми остальными параметрами отсутствует, что соответствует характеру рассматриваемого процесса измерения; однако между величинами s_k , коэффициентом усиления G и смещением нуля U_{off} коэффициенты корреляции равны 1 (линейная функциональная зависимость).

Некоторые результаты последнего исследования приведены на рисунке 4 и отражены в таблице 2. Так для синусоидального сигнала с амплитудой 9,76 В (ДЗ равно 6,9 В) суммарная стандартная неопределенность получилась равной 0,28 В для некоррелированных параметров и 1,1 В для случая учета полной корреляции. Если считать случайные факторы, влияющие на величины s_k , распределенными нормально, то отрезок $[-3\sigma, 3\sigma]$ будет соответствовать доверительному интервалу для уровня значимости $\alpha = 0$ и совпадать с α -срезом полученной СНП для этого же уровня значимости. Этот случай показан на рисунке 4 и представлен в таблице 2.

Методика измерения гармонического состава сигнала

Алгоритм оценки параметров гармоник [27] впоследствии был применен для анализа синусоидальных сигналов, содержащих сигналы основной частоты и гармоники с различными значениями амплитуд и начальных фаз. Полученные результаты подтверждают корректность предложенной методики.

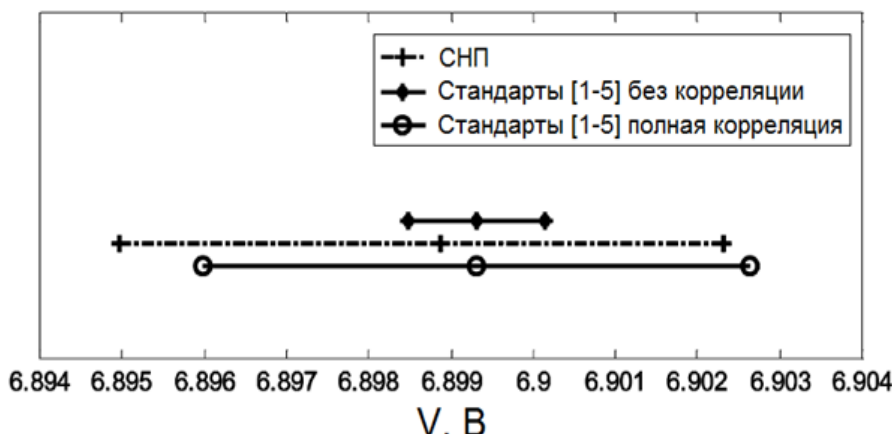


Рисунок 5 – Сравнение доверительных интервалов, полученных по СНП методике и рекомендациям стандартов [1–5]

Таблица 2 – Сравнение доверительных интервалов, полученных предложенным методом, с доверительными интервалами, рекомендованными в источниках [1–5], при отсутствии и наличии сравнения. Доверительные интервалы получены из условия неопределенности с применением коэффициента охвата $k = 3$

ДЗ, установленное на калибраторе	α -отрезок СНП для $\alpha = 0$	Доверительный интервал при отсутствии корреляций	Доверительный интервал при наличии корреляции
6,90 В \pm 1,30 мВ	6,8988 В $\begin{cases} -3,91 \text{ мВ} \\ +3,45 \text{ мВ} \end{cases}$	6,89931 В $\begin{cases} -0,84 \text{ мВ} \\ +0,84 \text{ мВ} \end{cases}$	6,89931 В $\begin{cases} -3,33 \text{ мВ} \\ +3,33 \text{ мВ} \end{cases}$

Из рисунка 5 и таблицы 2 видно, что СНП, связанные с амплитудой основной гармоники для каждого установленного ДЗ, по-прежнему охватывают заданное значение и соответствующий доверительный интервал. Были получены результаты, аналогичные представленным в таблице 1. В этом случае ширина внутренних интервалов каждого α -отрезка немного шире, так как увеличивается количество вычислений. Действительно, все неслучайные факторы, вносящие свои вклады

в результирующую неопределенность, не компенсируются предлагаемым алгоритмом; кроме того, они часто увеличивают внутренний интервал каждого α -отрезка при каждом новом вычислении.

На рисунке 6 представлены результаты измерений для первых нечетных гармоник (1, 3, 5, 7) треугольного сигнала, созданного тем же калибратором. Калибратор был настроен на треугольный сигнал с пиковой амплитудой 9,5 В. На данном рисунке также представлены расчетные теоретические величины амплитуд гармоник. Важно подчеркнуть, что все теоретически полученные значения находятся в пределах допустимой стандартной неопределенности и охватываются соответствующими СНП.

ЗАКЛЮЧЕНИЕ

Предложена методика оценки в онлайн-режиме неопределенности измерений цифровой измерительной аппаратуры, основанной на ЦОС. Методика заключается в представлении результата измерения и связанной с ним неопределенности с помощью СНП. Проведенные исследования показали, что такой подход позволяет вычислять доверительные интервалы для любых требуемых значений доверительной вероятности, которые должны охватывать результат измерения. Более того, ожидается, что использование СНП также может наглядно продемонстрировать, как различные вклады в неопределенность, обусловленные случайными и неслучайными факторами, влияют на конечный результат измерения [12].

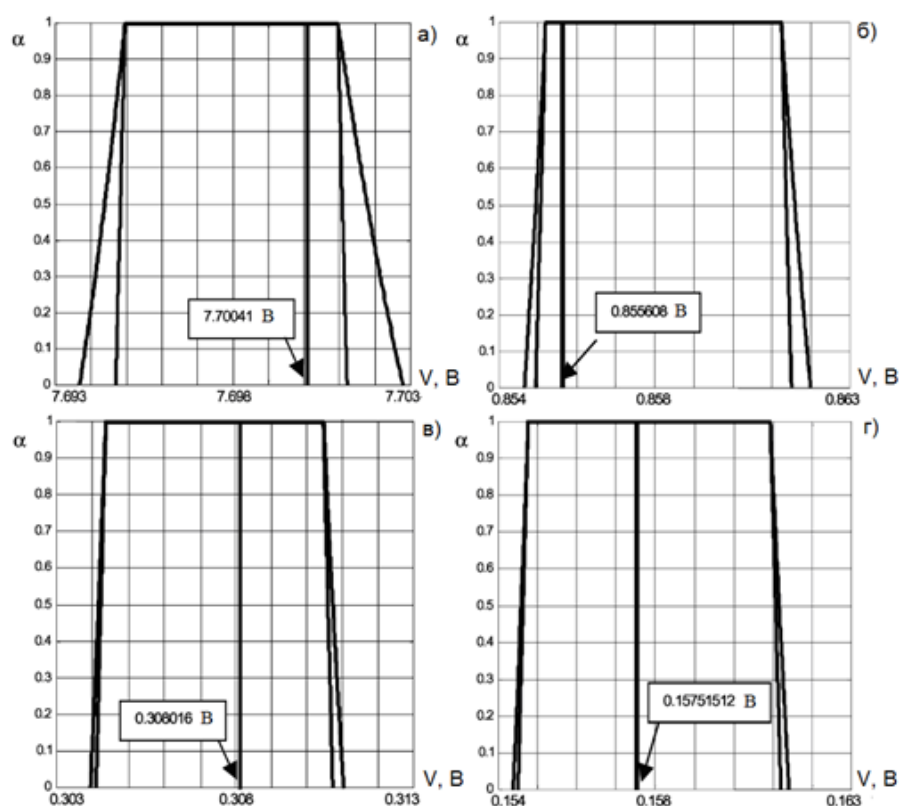


Рисунок 6 – СНП для значений первой а), третьей б), пятой в) и seventh г) гармоник сигнала треугольной формы с амплитудой 9,5 В. Стрелками показаны реальные значения амплитуд гармоник

Экспериментальные результаты, приведенные в работе, свидетельствуют о том, что методика на основе СНП в состоянии не только обеспечивать доверительные интервалы для нужных уровней значимости, но и представлять вклады различных факторов в результирующую неопределенность. Более того, методика не требует большого объема необходимых вычислений, что позволяет оперативно проводить расчет неопределенности. Главным преимуществом предлагаемого ограничения в условиях существующих методов онлайн-оценки неопределенности является его способность полностью использовать все возможности СНП. Учитывая все вышеизложенные факты, можно сделать вывод, что использование СНП представляет собой перспективную альтернативу традиционному вероятностному подходу [1–5] для оценки неопределенности в измерениях.

Список источников

1. BIPM, IEC, IFCC, ISO, IUPAC, IUPAP, and OIML. Guide to the Expression of Uncertainty in Measurement. – Geneva : ISO, 1995. – 118 p.
2. ISO/IEC Guide 98-1:2024 Guide to the Expression of Uncertainty in Measurement – Part 1: Introduction. – 1998. – 13 p.

3. ISO/IEC GUIDE 98-3:2008. Uncertainty of Measurement – Part 3: Guide to the Expression of Uncertainty in Measurement. – Geneva : ISO, 2010. – 120 p.
4. ГОСТ Р 34100.1-2017/ ISO/IEC Guide 98-1:2009. Неопределенность измерения. Часть 1. Введение в руководство по выражению неопределенности измерения. – Москва : Стандартинформ, 2018. – 22 с.
5. ГОСТ Р 54500.1-2011/Руководство ИСО/МЭК 98-3:2008. Неопределенность измерения. Часть 3. Руководство по выражению неопределенности измерения. – Москва : Стандартинформ, 2011. – 57 с.
6. Betta, G. Structured Approach to Estimate the Measurement Uncertainty in Digital Signal Elaboration Algorithms / G. Betta, C. Liguori, A. Pietrosanto // IEE Proc. on Science Measurement and Technology, 1999. – Vol. 146 (1). – P. 21–26. – DOI: 10.1049/ip-smt:19990001.
7. Betta, G. Propagation of Uncertainty in a Discrete Fourier Transform Algorithm / G. Betta, C. Liguori, A. Pietrosanto // Measurement, 2000. – Vol. 27. – P. 231–239. – DOI 10.1016/S0263-2241(99)00068-8.
8. Ferrero, A. A Calibration Procedure for a Digital Instrument for Electric Power Quality Measurement / A. Ferrero, M. Lazzaroni, S. Salicone // IEEE Trans. on Instrumentation and Measurement, 2002. – Vol. 51, № 8. – P. 716–722. – DOI 10.1109/IMTC.2001.928823.
9. Liguori, C. Implementing Uncertainty Auto-Evaluation Capabilities on an Intelligent FFT Analyzer / C. Liguori, A. Paolillo // IEEE Trans. on Instrumentation and Measurement, 2004. – Vol. 53, № 3. – P. 700–708. – DOI 10.1109/TIM.2004.827074.
10. Ferrero, A. An Innovative Approach to the Determination of Uncertainty in Measurements Based on Fuzzy Variables / A. Ferrero, S. Salicone // IEEE Trans. on Instrumentation and Measurement, 2003. – Vol. 52, № 4. – P. 1174–1181. – DOI 10.1109/TIM.2003.815993.
11. Ferrero, A. The Random-Fuzzy Variables: A New Approach for the Expression of Uncertainty in Measurement / A. Ferrero, S. Salicone // IEEE Trans. Instrum. Meas. – 2004. – Vol. 53, № 5. – P. 1370–1377.
12. Львов, А. А. Альтернативный подход к выражению неопределенности измерения в эксперименте / А. А. Львов, П. А. Шаронов, Н. С. Вагарина и др. // Математическое моделирование, компьютерный и натуральный эксперимент в естественных науках. – 2021. – № 3. – URL: mathmod.esrae.ru/35-130 (дата обращения: 01.04.2025).
13. Shafer, G. A Mathematical Theory of Evidence / G. Shafer. – NJ : Princeton Univ. Press, 1976. – 300 p.
14. Salicone, S. The Mathematical Theory of Evidence and Measurement Uncertainty – Comparison of Measurement Results Expressed in Terms of Random-Fuzzy Variables / S. Salicone // IEEE Instrum. & Meas. Mag. – 2014. – Vol. 17, № 6. – P. 14–18. – DOI 10.1109/MIM.2014.6968924.
15. Salicone, S. Measurement Uncertainty: An Approach via the Mathematical Theory of Evidence / S. Salicone. – New York : Springer, 2007. – 228 p.
16. Klir, G. J. Fuzzy Sets and Fuzzy Logic. Theory and Applications / G. J. Klir, B. Yuan. – Englewood Cliffs, NJ : Prentice-Hall, 1995. – 592 p.
17. Kaufman, A. Introduction to Fuzzy Mathematics: Theory and Applications / A. Kaufman, M. M. Gupta. – New York : Van Nostrand Reinhold, 1985. – 351 p.
18. Львов, А. А. Основы статистической обработки измерительной информации в задачах автоматического управления: учеб. пособие для студ. вузов / А. А. Львов. – Саратов : СГТУ, 2005. – 84 с.
19. Bhandari, P. Ratio Scales: Definition, Examples, & Data Analysis / P. Bhandari // Scribbr. – 2023, December 29. – URL: <https://www.scribbr.com/statistics/ratio-data/> (дата обращения: 01.04.2025).
20. Mauris, G. A Fuzzy Approach for the Expression of Uncertainty in Measurement / G. Mauris, V. Lasserre, L. Foulloy // Measurement, 2001. – Vol. 29, iss. 3. – P. 165–177. [https://doi.org/10.1016/S0263-2241\(00\)00036-1](https://doi.org/10.1016/S0263-2241(00)00036-1)
21. Mauris, G. A Simple Probability-Possibility Transformation for Measurement Error Representation: A Truncated Triangular Transformation / G. Mauris, V. Lasserre, L. Foulloy // Proc. of the World Congr. of Int. Fuzzy Systems Association. – Prague, Czech Republic, 1997. – P. 476–481.
22. Солопекина А. А. Применение метода неопределенности для анализа погрешностей многополюсного рефлектометра / А. А. Солопекина, А. А. Львов, Н. Семежев, Н. С. Вагарина // Надежность и качество : тр. Междунар. симп. : в 2 т. – Пенза : ПГУ, 2017. – Т. 2. – С. 136–139.
23. Solopekina, A. A. Calculation of measurement uncertainties of multi-port transmission line reflectometer / A. A. Solopekina, A. A. L'vov, N. Semezhev // Proc. 2014 Int. Conf. on Actual Problems of Electron Devices Engineering. – Saratov, Russia : IEEE, 2014. – P. 356–362.
24. Львов, А. А. Расчет неопределенностей измерения характеристик многозондовой измерительной линии / А. А. Львов, А. А. Солопекина, Н. Семежев // Компьютерные науки и информационные технологии : материалы Междунар. науч. конф. – Саратов : Наука, 2016. – С. 396–400.
25. Solopekina, A. A. Application of the Uncertainty Method for Analysis of Multi-Port Correlator Accuracy / A. A. Solopekina, N. Semezhev, M. S. Svetlov et al. // Proc. 2017 IEEE Russia Section Young Researchers in Electrical and Electronic Engineering Conf. – St. Petersburg, Russia : IEEE, 2017. – P. 505–509.
26. Балабан, О. М. Измерения длины в Древней Греции: неопределенность стандартов в золотой век Олимпийских игр / О. М. Балабан, В. В. Балабан, А. А. Львов, М. С. Светлов // Проблемы управления, обработки и передачи информации : сб. тр. VI Междунар. науч. конф. – Саратов: ООО СОП «Лодии», 2019. – С. 611–620.
27. Dolinina, O. Estimating Algorithm for Harmonics of Current and Voltage Signals When Measuring Reactive Power in Industrial Power Networks / O. Dolinina, O. Toropova, E. L'vova, N. Vagarina // Studies in Systems, Decision and Control. – Springer Nature Switzerland, 2020. – Vol. 337. – P. 250–271. – DOI 10.1007/978-3-030-65283-8_21.

References

1. BIPM, IEC, IFCC, ISO, IUPAC, IUPAP, and OIML. *Guide to the Expression of Uncertainty in Measurement*. Geneva, ISO, 1995. 118 p.
2. *ISO/IEC Guide 98-1:2024 Guide to the Expression of Uncertainty in Measurement – Part 1: Introduction*, 1998. 13 p.
3. *ISO/IEC GUIDE 98-3:2008. Uncertainty of Measurement – Part 3: Guide to the Expression of Uncertainty in Measurement*. Geneva, ISO, 2010. 120 p.
4. *GOST R 34100.1-2017/ISO/IEC Guide 98-1:2009. Uncertainty of measurement. Part 1. Introduction to guides for the expression of uncertainty in measurement*. Moscow, Standartinform, 2018. 22 p. (In Russ.).
5. *GOST R 54500.1-2011/ISO/IEC Guide 98-3:2008. Uncertainty of measurement. Part 3. Guide to the expression of uncertainty in measurement*. Moscow, Standartinform, 2011. 57 p. (In Russ.).
6. Betta, G., Liguori, C., Pietrosanto, A. Structured Approach to Estimate the Measurement Uncertainty in Digital Signal Elaboration Algorithms. *IEE Proc. on Science Measurement and Technology*, 1999, vol. 146 (1), pp. 21–26. DOI: 10.1049/ip-smt:19990001.
7. Betta, G., Liguori, C., Pietrosanto, A. Propagation of Uncertainty in a Discrete Fourier Transform Algorithm. *Measurement*, 2000, vol. 27, pp. 231–239. DOI 10.1016/S0263-2241(99)00068-8.
8. Ferrero, A., Lazzaroni, M., Salicone, S. A Calibration Procedure for a Digital Instrument for Electric Power Quality Measurement. *IEEE Trans. on Instrumentation and Measurement*, 2002, vol. 51, no. 8, pp. 716–722. DOI 10.1109/IMTC.2001.928823.
9. Liguori, C., Paolillo, A. Implementing Uncertainty Auto-Evaluation Capabilities on an Intelligent FFT Analyzer. *IEEE Trans. on Instrumentation and Measurement*, 2004, vol. 53, no. 3, pp. 700–708. DOI 10.1109/TIM.2004.827074.
10. Ferrero, A., Salicone, S. An Innovative Approach to the Determination of Uncertainty in Measurements Based on Fuzzy Variables. *IEEE Trans. on Instrumentation and Measurement*, 2003, vol. 52, no. 4, pp. 1174–1181. DOI 10.1109/TIM.2003.815993.
11. Ferrero, A., Salicone, S. The Random-Fuzzy Variables: A New Approach for the Expression of Uncertainty in Measurement. *IEEE Trans. Instrum. Meas.*, 2004, vol. 53, no. 5, pp. 1370–1377.
12. Lvov, A. A., Sharonov, P. A., Vagarina, N. S. et al. An Alternative Approach to Expressing Uncertainty of Measurement in an Experiment. *Mathematical Modeling, Computer and Natural Experiments in the Natural Sciences*, 2021, no. 3. Available at: mathmod.esrae.ru/35-130 (accessed 01.04.2025) (In Russ.).
13. Shafer, G. *A Mathematical Theory of Evidence*. NJ, Princeton Univ. Press, 1976. 300 p.
14. Salicone, S. The Mathematical Theory of Evidence and Measurement Uncertainty – Comparison of Measurement Results Expressed in Terms of Random-Fuzzy Variables. *IEEE Instrum. & Meas. Mag.*, 2014, vol. 17, no. 6, pp. 14–18. DOI 10.1109/MIM.2014.6968924.
15. Salicone, S. *Measurement Uncertainty: An Approach via the Mathematical Theory of Evidence*. New York, Springer, 2007. 228 p.
16. Klir, G. J., Yuan, B. *Fuzzy Sets and Fuzzy Logic. Theory and Applications*. Englewood Cliffs, NJ, Prentice-Hall, 1995. 592 p.
17. Kaufman, A., Gupta, M. M. *Introduction to Fuzzy Mathematics: Theory and Applications*. New York, Van Nostrand Reinhold, 1985. 351 p.
18. Lvov, A. A. *Fundamentals of statistical processing of measurement information in automatic control problems: a textbook for students of higher education institutions*. Saratov, SSTU, 2005. 84 p. (In Russ.).
19. Bhandari, P. Ratio Scales: Definition, Examples, & Data Analysis. *Scribbr.*, 2023, December 29. URL: <https://www.scribbr.com/statistics/ratio-data/> (дата обращения: 01.04.2025).
20. Mauris, G., Lasserre, V., Foulloy, L. A Fuzzy Approach for the Expression of Uncertainty in Measurement. *Measurement*, 2001, vol. 29, iss. 3, pp. 165–177. [https://doi.org/10.1016/S0263-2241\(00\)00036-1](https://doi.org/10.1016/S0263-2241(00)00036-1).
21. Mauris, G., Lasserre, V., Foulloy, L. A Simple Probability-Possibility Transformation for Measurement Error Representation: A Truncated Triangular Transformation. *Proc. of the World Congr. of Int. Fuzzy Systems Association*. Prague, Czech Republic, 1997, pp. 476–481.
22. Solopekina, A. A., Lvov, A. A., Semezhev, N., Vagarina, N. S. Application of the uncertainty method to analyze the errors of a multi-pole reflectometer. *Reliability and quality : proc. of the Int. symp.: in 2 vol.* Penza, PSU, 2017, vol. 2, pp. 136–139 (In Russ.).
23. Solopekina, A. A., Semezhev, N. Calculation of measurement uncertainties of multi-port transmission line reflectometer. *Proc. 2014 Int. Conf. on Actual Problems of Electron Devices Engineering*. Saratov, Russia, IEEE, 2014, pp. 356–362.
24. Lvov, A. A., Solopekina, A. A. and Semezhev, N. Calculation of Uncertainties in Measuring the Characteristics of a Multi-Probe Measuring Line. *Computer Sciences and Information Technologies: Proceedings of the International Scientific Conference*. Saratov, Publishing Center "Nauka", 2016, pp. 396–400 (In Russ.).
25. Solopekina, A. A., Semezhev, N., Svetlov, M. S. et al. Application of the Uncertainty Method for Analysis of Multi-Port Correlator Accuracy. *Proc. 2017 IEEE Russia Section Young Researchers in Electrical and Electronic Engineering Conf.* St. Petersburg, Russia, IEEE, 2017, pp. 505–509.
26. Balaban, O. M., Balaban, V. V., Lvov, A. A. and Svetlov, M. S. Measurements of Length in Ancient Greece: Uncertainty of Standards in the Golden Age of the Olympic Games. *Problems of Information Management, Processing, and Transmission: Proceedings of the 6th International Scientific Conference*. Saratov, Lodi LLC, 2019, pp. 611–620 (In Russ.).
27. Dolinina, O., Toropova, O., L'vova, E., Vagarina, N. Estimating Algorithm for Harmonics of Current and Voltage Signals When Measuring Reactive Power in Industrial Power Networks. *Studies in Systems, Decision and Control*. Springer Nature Switzerland, 2020, vol. 337, pp. 250–271. DOI 10.1007/978-3-030-65283-8_21.

Статья поступила в редакцию 09.09.2025; одобрена после рецензирования 28.09.2025; принята к публикации 30.09.2025.

The article was submitted 09.09.2025; approved after reviewing 28.09.2025; accepted for publication 30.09.2025.

МЕТОДЫ И СИСТЕМЫ ЗАЩИТЫ ИНФОРМАЦИИ, ИНФОРМАЦИОННАЯ БЕЗОПАСНОСТЬ

УДК 004.85

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ ДЛЯ ОБНАРУЖЕНИЯ И ПРЕДОТВРАЩЕНИЯ ФИШИНГОВЫХ АТАК, НАПРАВЛЕННЫХ НА КРАЖУ ПЕРСОНАЛЬНЫХ ДАННЫХ

Частикова Вера Аркадьевна, Кубанский государственный технологический университет, 350072, Российская Федерация, г. Краснодар, ул. Московская, 2,

кандидат технических наук, доцент, ORCID:0000-0003-2372-8275, e-mail: chastikova_va@mail.ru

Козачек Константин Валериевич, Кубанский государственный технологический университет, 350072, Россия, г. Краснодар, ул. Московская, 2,

аспирант, ORCID: 0009-0002-9945-2113, e-mail: Koza4ek.Konstantin@yandex.ru

Чикиндина Екатерина Александровна, Кубанский государственный технологический университет, 350072, Российская Федерация, г. Краснодар, ул. Московская, 2,

студент, ORCID: 0009-0005-6830-9156, e-mail: kchikindina@gmail.com

Бушueva Полина Валерьевна, Кубанский государственный технологический университет, 350072, Российская Федерация, г. Краснодар, ул. Московская, 2,

студент, ORCID: 0009-0005-9460-1804, e-mail: polinabuschueva@gmail.com

Фишинговые атаки представляют собой серьезную угрозу безопасности персональных данных. Традиционные методы защиты часто оказываются недостаточно эффективными против постоянно совершенствующихся техник злоумышленников. Данная статья исследует применение технологий искусственного интеллекта для повышения точности обнаружения и предотвращения фишинговых атак. Предложено использовать многослойный перцептрон для анализа различных характеристик фишинговых URL-адресов и веб-страниц с акцентом на анализе структуры URL и выделения гиперпараметров ссылок. Результаты тестирования на обширном наборе данных, включающем 10000 легитимных и фишинговых ссылок, демонстрируют высокую эффективность разработанной системы обнаружения фишинговых атак, достигая точности в 96,53 %. Работа вносит вклад в развитие методов защиты от фишинга, предлагая более надежный и адаптивный подход к борьбе с этой растущей угрозой.

Ключевые слова: фишинг, нейронная сеть, машинное обучение, многослойный перцептрон, персональные данные, защита данных, бинарная кросс-энтропия

APPLICATION OF NEURAL NETWORK METHODS TO DETECT AND PREVENT PHISHING ATTACKS AIMED AT STEALING PERSONAL DATA

Chastikova Vera A., Kuban State Technological University, 2 Moskovskaya St., Krasnodar, 350072, Russian Federation,

Cand. Sci. (Engineering), Associate Professor, ORCID:0000-0003-2372-8275, e-mail: chastikova_va@mail.ru

Kozachek Konstantin V., Kuban State Technological University, 2 Moskovskaya St., Krasnodar, 350072, Russian Federation,

postgraduate student, ORCID: 0009-0002-9945-2113, e-mail: Koza4ek.Konstantin@yandex.ru

Chikindina Ekaterina A., Kuban State Technological University, 2 Moskovskaya St., Krasnodar, 350072, Russian Federation,

specialist, ORCID: 0009-0005-6830-9156, e-mail: kchikindina@gmail.com

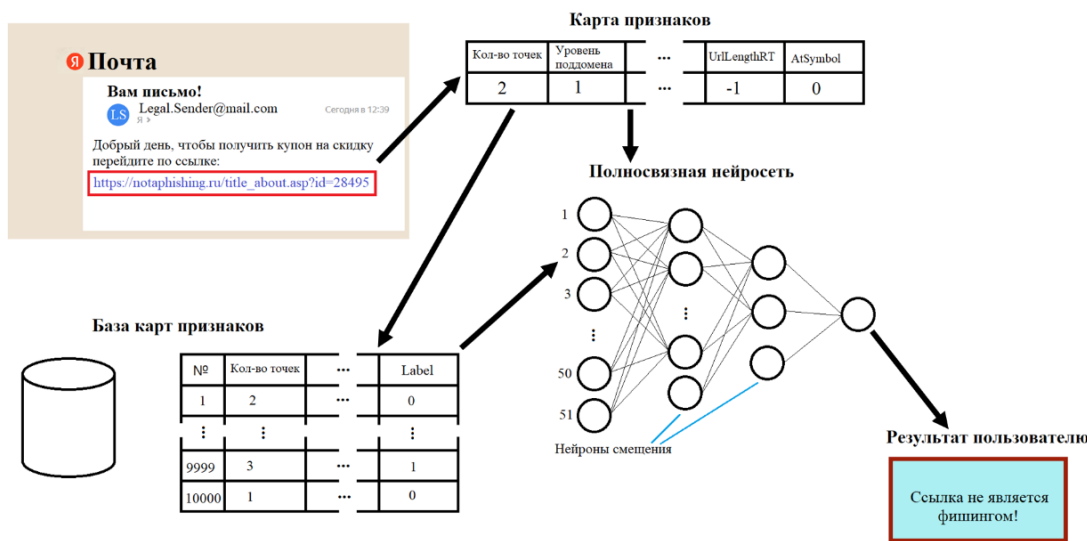
Bushueva Polina V., Kuban State Technological University, 2 Moskovskaya St., Krasnodar, 350072, Russian Federation,

specialist, ORCID: 0009-0005-9460-1804, e-mail: polinabuschueva@gmail.com

Phishing attacks pose a serious threat to the security of personal data. Traditional defense methods are often ineffective against the constantly improving techniques of attackers. This paper explores the use of artificial intelligence (AI) to improve the accuracy of detection and prevention of phishing attacks. We propose to use a multilayer perceptron to analyze various characteristics of phishing URLs and web pages, including lexical text analysis, URL structure analysis, visual features. Testing results on an extensive dataset of 10,000 legitimate and phishing links demonstrate the high efficiency of the developed system in detecting phishing attempts, achieving an accuracy of 96.53 %. The work contributes to the development of anti-phishing methods by offering a more robust and adaptive approach to combat this growing threat.

Keywords: phishing, neural network, machine learning, multilayer perceptron, personal data, data protection, binary cross entropy

Graphical annotation (Графическая аннотация)



ВВЕДЕНИЕ

Фишинговые атаки – вид онлайн-мошенничества, который используется для обмана пользователей интернета с целью получения их персональных данных. Фишинговые атаки представляют собой серьезную и постоянно растущую угрозу кибербезопасности. Статистика свидетельствует об их масштабах: по информации на октябрь 2024 г., количество фишинговых атак в России выросло на 425 % с начала года по сравнению с предыдущим 2023 г. По данным сервиса Bi.Zone Brand Protection, количество обнаруженных фишинговых ресурсов в России за 2024 г. превысило 350 тыс., что более чем в полтора раза больше показателя 2023 г. (210 тыс.) [1].

Помимо прямых финансовых потерь и утечки персональных данных, фишинговые атаки несут значительные репутационные риски для организаций и отдельных лиц. Традиционные методы обнаружения фишинга, такие как спам-фильтры и анализ ключевых слов, оказываются все менее эффективными перед лицом постоянно совершенствующихся фишинговых техник. Быстрое развитие методов обхода традиционных мер защиты требует новых, более адаптивных подходов.

Цель данного исследования – оценить потенциал искусственного интеллекта (ИИ) в обнаружении и предотвращении фишинговых атак, направленных на кражу персональных данных (ПДн). Для этого будут проанализированы существующие методы обнаружения фишинга на основе ИИ, разработана модель, протестирована ее эффективность и сравнены результаты с традиционными методами. В исследовании будет использован метод многослойного перцептрона, с оценкой эффективности по таким метрикам, как точность, бинарная кросс-энтропия, время обучения и матрица ошибок.

АНАЛИЗ ФИШИНГОВЫХ АТАК

Современные фишинговые атаки демонстрируют поразительное разнообразие методов и каналов распространения, что говорит об их высокой адаптивности к мерам защиты. Можно выделить несколько основных типов:

1. Фишинг по электронной почте (Email Phishing): классический метод, использующий поддельные письма, имитирующие сообщения от легитимных источников (банков, сервисов или знакомых). Письма содержат вредоносные ссылки или вложения, которые перенаправляют пользователя на фальшивые веб-ресурсы либо инициируют запуск вредоносного программного обеспечения (ПО). Важным элементом является использование социальной инженерии, создающей ощущение срочности или угрозы [2]. В таких случаях появляется проблема обнаружения спама, который предшествует фишинговой атаке [3].

2. Фишинг в социальных сетях (Social Engineering Phishing): злоумышленники используют платформы социальных сетей для установления доверительного контакта с жертвой, маскируя себя за друга, коллегу или представителя организации. Данные действия позволяют получить конфиденциальную информацию путем эксплуатации дружеских взаимоотношений.

3. Веб-фишинг (Website Phishing): создаются поддельные веб-сайты с минимальными визуальными отличиями от легитимных ресурсов. Тем самым жертва, переходя на такой сайт и вводя личную информацию, передает данные о себе в руки мошенников. Поддельные сайты часто используют очень похожие доменные имена, отличающиеся на одну букву или символ.

4. СМС-фишинг (Smishing): реализуется через рассылку SMS-сообщения, содержащих вредоносные ссылки или запросы на предоставление персональных данных. Метод часто применяется для компрометации банковских реквизитов и учетных записей.

5. Внутрикorporативный фишинг (Internal Phishing): нацелен на сотрудников компании и использует внутреннюю инфраструктуру для повышения эффективности. Злоумышленники, получив доступ ранее или являясь сотрудником, выдают себя за коллег или руководство, запрашивая доступ к критически важным данным.

6. Голосовой фишинг (Vishing): осуществляется посредством телефонных звонков, в ходе которых злоумышленник, выдавая себя за представителя банка, техподдержки или госучреждения, склоняет жертву к раскрытию конфиденциальной информации с применением методов психологического воздействия.

Все эти типы фишинга часто комбинируются, используются различные методы социальной инженерии и технические уловки для максимальной эффективности [4]. Понимание этих методов необходимо для разработки эффективных мер защиты.

Основными характеристиками фишинговых атак являются:

- использование обмана: основано на имитации доверенных источников, с использованием поддельных сообщений, веб-сайтов или других каналов;
- применение социальной инженерии: манипулирование психологическими триггерами, используя страх, срочность, доверие и другие уловки;
- разнообразие методов: применение различных коммуникационных платформ (электронная почта, SMS, социальные сети, телефонные звонки) и технические приемы (поддельные веб-сайты, вредоносное ПО);
- высокая эффективность: атаки относительно несложны в организации при значительном потенциале ущерба;
- постоянная эволюция: злоумышленники непрерывно усложняют свои методы, затрудняя обнаружение и предотвращение.

Успешные атаки опираются на синтез технических уловок, таких как поддельные веб-сайты и вредоносное ПО, и методов психологического манипулирования, использующего социальную инженерию. Эффективная защита требует комплексного подхода, включающего технические средства (антивирусные программы, системы обнаружения вторжений, многофакторная аутентификация), меры по повышению осведомленности пользователей тактиках социальной инженерии, постоянный мониторинг новых векторов атак и адаптация защитных механизмов. Понимание мотивов злоумышленников и их методов позволяет создавать более эффективные стратегии защиты и реагирования на подобные атаки.

СРАВНЕНИЕ ПРЕДЫДУЩИХ ИССЛЕДОВАНИЙ

В представленной ниже таблице приведена сравнительная характеристика ранее проведенных исследований по теме работы.

Таблица 1 – Сравнительная характеристика ранее проведенных исследований

Авторы исследований	Год публикации	Модель машинного обучения	Датасет	Результаты, % (Accuracy)
Sohail Ahmed Khan, Wasiq Khan, Abir Hussain [5]	2020	– случайный лес – метод опорных векторов – логистическая регрессия	Alexa, PhishTank, OpenPhish	RF 93,7, SVM 91,5, LR 90,8
E. Sri Vishva, D. Aju [6]	2021	TF-IDF+ML	Фишинговые и легитимные URL-адреса	95,1
Sarasjati W., Rustad S., Santoso H. A., Syukur A., Rafrastara F. A. [7]	2022	– дерево решений – случайный лес – метод опорных векторов – наивный байесовский классификатор	UCI ML Repository	RF – 94, SVM – 92,6, DT 9 – 0,3, NB – 88,1
MohammedAl-Sarem, Faisal Saeed, Zeyad Ghaleb Al-Mekhlafi, Badiea Abdulkarem Mohammed Tawfik Al-Hadhrani, Mohammad T. Alshammari, Abdulrahman Alreshidi and Talal Sarheed Alshammari [8]	2021	Оптимизированное стекирование	UCI ML Repository	97,2

Во многих исследованиях используется набор данных UCI ML Repository, содержащий более 200 000 записей. Он очень подробно описывает адрес и код страницы, однако это является ключевым недостатком датасета. Хотя подход, основанный на анализе страницы, может давать несколько более высокую точность за счет большего объема информации [8], его фундаментальное ограничение – необходимость перехода по потенциально фишинговой ссылке – делает его менее применимым в качестве превентивной меры защиты пользователей.

МЕТОДОЛОГИЯ ИССЛЕДОВАНИЙ

Для быстрого определения, является сайт легитимным или нет, необходимо посмотреть на URL-ссылку, так как именно ее злоумышленник делает максимально похожей на настоящую. Она может содержать в себе несколько уровней, использовать различные символы. Исследования показывают, что использование методов машинного обучения эффективнее применения традиционных методов выявления фишинговых ссылок [9].

С целью обучения модели был взят готовый набор данных Phishing_Legitimate_full.csv с открытой платформы Kaggle [10]. Данный набор содержит в себе 48 признаков, которые были извлечены с помощью усовершенствованной технологии, основанной на фреймворке автоматизации браузера из адресных строк 10000 веб-страниц.

В отличие от широко используемых датасетов, таких как UCI ML Repository [7, 8], которые требуют извлечения признаков из исходного кода загруженной веб-страницы (HTML, JavaScript), выбранный авторами датасет Phishing_Legitimate_full.csv [10] содержит признаки, полученные исключительно на основе анализа строки URL-адреса и внешних запросов (например, команды WHOIS). Это является принципиальным преимуществом с точки зрения практической применимости и безопасности:

- классификатор может определить фишинговую природу ссылки до перехода пользователя на потенциально вредоносный сайт, исключая риск непреднамеренной загрузки эксплойтов или взаимодействия с фальшивыми формами;
- анализ строки URL выполняется на порядки быстрее и требует значительно меньше вычислительных ресурсов, чем полная загрузка и парсинг веб-страницы, что критично для систем реального времени;
- такой подход упрощает интеграцию в существующие защитные механизмы, где часто известен только URL страницы.

Для создания модели и дальнейшей проверки результатов представленный набор необходимо разделить на тренировочные и тестовые данные соответственно. Используется стандартное соотношение: 70 % – на обучающий набор, необходимый для настройки параметров, и оставшиеся 30 % – на валидационный, который позволит оценить реальную производительность модели.

Следующим шагом необходимо масштабировать данные. Этим действием данные приводятся к одному диапазону значений, что позволит устранить влияние различий в масштабах признаков, также это позволит ускорить обучение модели и повысить стабильность работы.

Проанализировав предыдущие исследования, было отмечено, что в различных моделях машинного обучения применялись разные исследуемые наборы данных и, соответственно, разные анализируемые параметры. В данных работах использовался набор из множества оценок функций, полученных из фишинговых и законных веб-страниц и функций однозначного идентифицирования.

В данной работе используется алгоритм контролируемого обучения – многослойный перцептрон. Указанная модель путем обучения на тестовом наборе находит отображения входных данных в выходное значение, $X \rightarrow Y$ для $\forall x \in X$. В ней формальные нейроны каждого слоя соединяются с каждым нейроном последующего и предыдущего слоев (рис. 1) [11, 15].

В результате чего на выходе достигается объединение многомерной функции при соответствующем выборе параметров сети.

В работе были использованы такие библиотеки, как numpy, pandas, sklearn, tensorflow, matplotlib, предназначенные для построения и обучения нейронной сети, обработки числовых данных и для визуализации результатов.

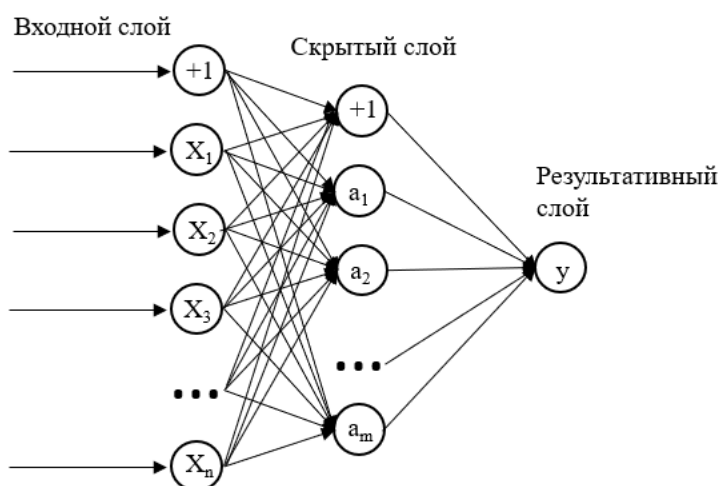


Рисунок 1 – Визуализация слов перцептрона

Архитектура нейронной сети представляет собой последовательную модель с полносвязными слоями. При этом на входном и внутренних слоях используются функции регуляризации L1 и L2, помогающие отбирать важные признаки и снижать вероятность переобучения, функция нормализации BatchNormalization, ускоряющая обучение и нормализуя предыдущие данные, функция активации Activation('relu'), улучшающая процесс за счет нелинейности и функция Dropout, которая случайным образом выключает определенный процент нейронов. Последний слой представлен одним нейроном с бинарной классификацией.

АНАЛИЗ ПОЛУЧЕННЫХ РЕЗУЛЬТАТОВ

В ходе исследования модель анализировала представленные 48 признаков, например, количество точек в URL, уровней в поддомене, длину и т. д.

Эффективность обучения оценивается за счет функции точности, функции потерь, а также времени, за которое нейронная сеть достигла наивысшего результата [13–15].

Точность описывает долю правильных предсказаний и рассчитывается как отношение количества правильных предсказаний к их общему количеству. Математически данную функцию можно описать следующим выражением:

$$\text{Точность} = \frac{TP+TN}{TP+TN+FP+FN},$$

где TP – истинно положительные предсказания;

TN – истинно отрицательные предсказания;

FP – ложно положительные предсказания;

FN – ложно отрицательные предсказания [12].

Бинарная кросс-энтропия (Binary Cross-Entropy, BCE) – это функция потерь, используемая в задачах бинарной классификации и выражающаяся в разнице между предсказанным и фактическим значением. Данное значение является основой обучения, поскольку процесс обучения направлен на минимизацию данной характеристики. Математически функция описывается в следующем виде:

$$BCE = -\sum_{i=1}^n y_i \log(y'_i),$$

где y_i – фактические значения;

y'_i – предсказанные значения [13].

В работе было проведено сравнение значений вышеуказанных параметров и времени обучения для различного количества слоев и нейронов созданной модели. Результаты представлены в таблице 2.

В результате лучшие значения были получены с использованием 3 слоев, с 64 нейронами на входном слое, 32 – на внутреннем и 1 – на внешнем.

Для визуализации процесса обучения представлены следующие графики. Максимальным значением точности для тренировочных данных является 96,16 % и 96,57 % – для валидационной части (рис. 2). Такое соотношение точности на разных наборах данных указывает на отсутствие переобучения и возможности масштабирования при увеличении датасета.

Таблица 2 – Результаты обучения с разными параметрами

Количество слов	Количество нейронов	Среднее время	Точность	ВСЕ	Количество эпох
3	(256, 128, 1)	4 мс/шаг	0,9587	0,2576	28
3	(512, 256, 1)	7 мс/шаг	0,9603	0,345	19
3	(128, 64, 1)	4 мс/шаг	0,958	0,2448	29
3	(128, 32, 1)	3 мс/шаг	0,9613	0,2309	37
3	(64, 32, 1)	4 мс/шаг	0,9653	0,2096	33
3	(32, 16, 1)	3 мс/шаг	0,962	0,1976	37
3	(1024, 512, 1)	13 мс/шаг	0,9467	0,4557	14
3	(1024, 256, 1)	10 мс/шаг	0,947	0,4919	14
4	(1024, 512, 256, 1)	16 мс/шаг	0,9497	0,4332	28
5	(1024, 512, 256, 128, 1)	17 мс/шаг	0,9563	0,4881	22
6	(1024, 512, 256, 128, 64, 1)	17 мс/шаг	0,9533	0,5963	13
7	(1024, 512, 256, 128, 64, 32, 1)	17 мс/шаг	0,948	0,5376	19
8	(1024, 512, 256, 128, 64, 32, 16, 1)	20 мс/шаг	0,9567	0,5357	27




Рисунок 2 – График значений точности

Для значения функции бинарной кросс-энтропии получен график (рис. 3), в котором минимальные значения достигаются в точке 0,2088 для обучающего набора и в точке 0,2007 для валидационного.




Рисунок 3 – График значений бинарной кросс-энтропии (ВСЕ)

Матрица ошибок представлена на рисунке 4.




Рисунок 4 – Матрица ошибок

ЗАКЛЮЧЕНИЕ

В результате проведенных исследований была разработана модель на основе многослойного перцептрона, обученная на датасете признаков, извлеченных исключительно из URL-адресов, которая продемонстрировала высокую точность классификации (96,53 %), сопоставимую с точностью исследований, требующих анализ контента загруженной веб-страницы, на значительно меньшем наборе данных.

Исследование можно развивать, увеличивая датасет за счет реальных, либо синтетических данных. В дальнейшем планируется использовать другие, более современные модели машинного обучения, такие как архитектуры трансформера.

Список источников

1. BI.ZONE Brand Protection: более чем в 1,5 раза увеличилось количество фишинга в 2024 году. – URL: <https://bi.zone/news/bi-zone-brand-protection-bolee-chem-v-1-5-raza-uvelichilos-kolichestvo-fishinga-v-2024-godu/> (дата обращения: 28.04.2025).
2. Прокопайло, А. А. Анализ фишинговых атак / А. А. Прокопайло // StudNet. – 2021. – № 7. – С. 1808–1813.
3. Частикова, В. А. Обзор актуальных проблем основных методов фильтрации спама и анализ их эффективности / В. А. Частикова, К. В. Козачек // Вестник Адыгейского государственного университета. Серия 4: Естественно-математические и технические науки. – 2021. – № 3 (286). – С. 98–106. – DOI 10.53598/2410-3225-2021-3-286-98-106. – EDN VCLCNK.
4. Частикова, В. А. Методы обработки естественного языка в решении задач обнаружения атак социальной инженерии / В. А. Частикова, К. В. Козачек, В. Г. Гуляй // Вестник Адыгейского государственного университета. Серия 4: Естественно-математические и технические науки. – 2021. – № 4 (291). – С. 95–108. – DOI 10.53598/2410-3225-2021-4-291-95-108. – EDN GQKLI.
5. Sohail, Ahmed Khan. Phishing Attacks and Websites Classification Using Machine Learning and Multiple Datasets (A Comparative Analysis) / Sohail Ahmed Khan, Wasiq Khan, Abir Hussain // Intelligent Computing Methodologies: 16th International Conference, ICIC 2020. – 2020. – P. 301–313.
6. Vishva, E. Sri. Fighter: Website Phishing Detection System Based on URL and Term Frequency-In Document Frequency V / E. Sri Vishva, D. Aju Phisher // Journal of Cyber Security and Mobility. – 2021. – Vol. 11, № 1. – P. 83–104.
7. Sarasjati, W., Rustad, S., Santoso, H., Syukur, A., Rafrastara, F. Comparative Study of Classification Algorithms for Website Phishing Detection on Multiple Datasets // International Seminar on Application for Technology of Information and Communication (iSemantic). – 2022. – P. 448–452.
8. Mohammed, Al-Sarem. An Optimized Stacking Ensemble Model for Phishing Websites Detection / Mohammed Al-Sarem, Faisal Saeed, Zeyad Ghaleb Al-Mekhlafi, Badiya Abdulkarem Mohammed, Tawfik Al-Hadhrami, Mohammad T. Alshammari, Abdulrahman Alreshidi, Talal Sarheed Alshammari // Electronics. – 2021. – № 10. – P. 1285.
9. Корнюхина, С. П. Исследование возможностей алгоритмов глубокого обучения для защиты от фишинговых атак / С. П. Корнюхина, О. Р. Лапонина // Международный журнал открытых информационных технологий. – 2023. – № 6. – С. 163–174/ – ISSN: 2307-8162.
10. Shashwat, Tiwari. Phishing Dataset for Machine Learning / Shashwat Tiwari. – URL: <https://www.kaggle.com/datasets/shashwatwork/phishing-dataset-for-machine-learning/data> (дата обращения: 11.04.2025).
11. Заенцев, И. В. Нейронные сети : учебное пособие / И. В. Заенцев. – Воронеж : Изд-во ВГУ, 1999. – 76 с.

12. Oona, Rainio. Evaluation metrics and statistical tests for machine learning / Oona Rainio, Jarmo Teuho, Riku Klén. // *Scientific Reports*. – 2024. – Vol. 14. – Article № 6086.
13. Функции потерь в машинном обучении: выбор, применение, оценка. – URL: <https://sky.pro/wiki/analytics/funktsii-poter-v-mashinnom-obuchenii-vybor-primenenie-otsenka/> (дата обращения: 11.04.2025).
14. Частикова, В. А. Нейроиммунный метод сжатия данных в системе анализа инцидентов информационной безопасности / В. А. Частикова, А. И. Митюгов // *Вестник Воронежского государственного университета*. Серия: Системный анализ и информационные технологии. – 2024. – № 4. – С. 76–87.
15. Частикова, В. А. Технологии искусственного интеллекта в информационной безопасности : монография / В. А. Частикова, С. А. Жерлицын, С. А. Митюгов. – Краснодар: Изд-во КубГТУ, 2024. – 315 с.

References

1. *BI.ZONE Brand Protection: the number of phishing attacks increased more than 1.5 times in 2024*. Available at: <https://bi.zone/news/bi-zone-brand-protection-bolec-chem-v-1-5-raza-uvelichilos-kolichestvo-fishinga-v-2024-godu/> (accessed 28.04.2025).
2. Prokopaylo, A. A. Analysis of phishing attacks. *StuDent*, 2021, no. 7, pp. 1808–1813 (In Russ.).
3. Chastikova, V. A., Kozachek, K. V. Review of current issues of the main spam filtering methods and analysis of their effectiveness. *Bulletin of Adyghe State University. Series 4: Natural, mathematical and technical sciences*, 2021, no. 3 (286), pp. 98–106. DOI 10.53598/2410-3225-2021-3-286-98-106. EDN VCLCNK (In Russ.).
4. Chastikova, V. A., Kozachek, K. V., Gulyai, V. G. Methods of natural language processing in solving problems of detecting social engineering attacks. *Bulletin of Adyghe State University. Series 4: Natural, mathematical and technical sciences*, 2021, no. 4 (291), pp. 95–108. DOI 10.53598/2410-3225-2021-4-291-95-108. EDN GQKLLA (In Russ.).
5. Sohail, Ahmed Khan, Wasiq, Khan, Abir, Hussain. Phishing Attacks and Websites Classification Using Machine Learning and Multiple Datasets (A Comparative Analysis). *Intelligent Computing Methodologies: 16th International Conference, ICIC 2020*, 2020, pp. 301–313.
6. Vishva, E. Sri, Phisher, D. Aju Fighter: Website Phishing Detection System Based on URL and Term Frequency-In Document Frequency V. *Journal of Cyber Security and Mobility*, 2021, vol. 11, no. 1, pp. 83–104.
7. Sarasjati, W., Rustad, S., Santoso, H., Syukur, A., Rafrastara, F. Comparative Study of Classification Algorithms for Website Phishing Detection on Multiple Datasets. *International Seminar on Application for Technology of Information and Communication (iSemantic)*, 2022, pp. 448–452.
8. Mohammed, Al-Sarem, Faisal, Saeed, Zeyad, Ghaleb Al-Mekhlafi, Badiea, Abdulkarem Mohammed, Tawfik ,Al-Hadhrami, Mohammad T., Alshammari, Abdulrahman, Alreshidi, Talal, Sarheed Alshammari. An Optimized Stacking Ensemble Model for Phishing Websites Detection. *Electronics*, 2021, no. 10, p. 1285.
9. Korniyukhina, S. P., Laponina, O. R. Study of the Possibilities of Deep Learning Algorithms for Protection against Phishing Attacks. *International Journal of Open Information Technologies*, 2023, no. 6, pp. 163–174. ISSN 2307-8162 (In Russ.).
10. Shashwat Tiwari. Phishing Dataset for Machine Learning. Available at: <https://www.kaggle.com/datasets/shashwatwork/phishing-dataset-for-machine-learning/data> (accessed 11.04.2025).
11. Zaentsev, I. V. *Neural Networks. Tutorial*. Voronezh, VSU Publishing House, 1999. 76 p. (In Russ.).
12. Oona, Rainio, Jarmo, Teuho, Riku, Klén. Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 2024, vol. 14, article no. 6086.
13. Loss functions in machine learning: selection, application, evaluation Available at: <https://sky.pro/wiki/analytics/funktsii-poter-v-mashinnom-obuchenii-vybor-primenenie-otsenka/> (accessed 11.04.2025) (In Russ.).
14. Chastikova, V. A., Mityugov, A. I. Neuroimmune data compression method in the information security incident analysis system. *Bulletin of the Voronezh State University. Series: Systems analysis and information technology*, 2024, no. 4, pp. 76–87 (In Russ.).
15. Chastikova V. A., Zherlitsyn, S. A., Mityugov, S. A. *Artificial intelligence technologies in information security : monograph*. Krasnodar: Publishing House of KubSTU, 2024. 315 p. (In Russ.).

Статья поступила в редакцию 20.06.2025; одобрена после рецензирования 25.07.2025; принята к публикации 29.07.2025.

The article was submitted 20.06.2025; approved after reviewing 25.07.2025; accepted for publication 29.07.2025.

УДК 004.057

МОДЕЛИРОВАНИЕ ПРОЦЕССА ПЕРЕДАЧИ ДАННЫХ ПО ПРОТОКОЛУ TCP В КРИПТОГРАФИЧЕСКИ ЗАЩИЩЕННЫХ КАНАЛАХ С ВЫСОКОЙ ЗАДЕРЖКОЙ И ОГРАНИЧЕННОЙ ПРОПУСКНОЙ СПОСОБНОСТЬЮ

Журавлев Максим Юрьевич, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а,

аспирант, e-mail: maksim_zhuravlev_99@list.ru

Хайтул Анастасия Всеволодовна, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а,

магистрант, ORCID: 0000-0003-2112-8145, e-mail: khaaaytul@icloud.com

Азмухамедов Искандар Маратович, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а,

доктор технических наук, профессор кафедры информационной безопасности, ORCID: 0000-0001-9058-123X, e-mail: aim_agtu@mail.ru

В работе исследуется производительность протокола TCP в криптографически защищенных сетях с высокой задержкой и ограниченной пропускной способностью канала, типичных, например, для спутниковых систем связи. Проведено моделирование и экспериментальное измерение работы четырех алгоритмов управления перегрузкой TCP: Cubic, Hybla, BBR и Vegas. Стенд включал в себя эмулятор сети, обеспечивающий задержку ~600 мс, потерю пакетов на уровне ~2 % и VPN-туннель между клиентом и сервером. Измерялась пропускная способность TCP-соединения и число повторных передач данных в режимах одиночного и нескольких параллельных потоков. Отмечены существенные различия в эффективности алгоритмов: современные алгоритмы BBR и Hybla значительно превосходят Cubic и Vegas по пропускной способности в сложных сетевых условиях. Однако рост скорости передачи сопровождается увеличением количества повторных передач. Проанализировано влияние свойств канала на параметры TCP-трафика и разработаны рекомендации по выбору алгоритма управления перегрузкой для защищенных каналов связи.

Ключевые слова: TCP, алгоритмы управления перегрузкой, пропускная способность, высокая задержка, VPN, криптографически защищенные каналы, TCP Cubic, TCP Hybla, TCP BBR, TCP Vegas, многопоточная передача, сетевой эмулятор, повторные передачи, модели TCP, сети с ограниченной пропускной способностью

SIMULATION OF THE TCP DATA TRANSMISSION PROCESS IN CRYPTOGRAPHICALLY SECURE CHANNELS WITH HIGH LATENCY AND LIMITED BANDWIDTH

Zhuravlev Maksim Yu., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

graduate student, e-mail: maksim_zhuravlev_99@list.ru

Khaytul Anastasia V., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

master's student, ORCID: 0000-0003-2112-8145, e-mail: khaaaytul@icloud.com

Azhmukhamedov Iskandar M., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

Doct. Sci. (Engineering), Professor of the Department of Information Security, ORCID: 0000-0001-9058-123X, e-mail: aim_agtu@mail.ru

The paper examines the performance of the TCP protocol in cryptographically secure networks with high latency and limited channel bandwidth, typical, for example, for satellite communication systems. Four TCP congestion control algorithms have been modeled and experimentally measured: Cubic, Hybla, BBR, and Vegas. The stand included a network emulator that provides a delay of ~600 ms, packet loss of ~2 % and a VPN tunnel between the client and the server. The throughput of a TCP connection and the number of data retransmissions in single and multiple parallel stream modes were measured. Significant differences in the efficiency of the algorithms are noted: modern BBR and Hybla algorithms significantly outperform Cubic and Vegas in terms of bandwidth in difficult network conditions. However, the increase in transmission speed is accompanied by an increase in the number of retransmissions. The influence of channel properties on TCP traffic parameters has been analyzed and recommendations have been developed for choosing an overload management algorithm for secure communication channels.

Keywords: TCP, congestion control algorithms, throughput, high latency, VPN, cryptographically secure channels, TCP Cubic, TCP Hybla, TCP BBR, TCP Vegas, parallel TCP streams, network emulator, retransmissions, TCP models, limited bandwidth networks

ВВЕДЕНИЕ

Обеспечение эффективной передачи данных по криптографически защищенным каналам связи в неблагоприятных сетевых условиях является актуальной задачей для современных информационных систем. К таким сложным условиям относятся большое время задержки сигнала (высокий Round Trip Time (RTT)) и ограниченная полоса пропускания канала, часто сопровождающиеся потерей пакетов. Криптографическая защита повышает информационную безопасность, обеспечивая конфиденциальность и целостность данных. Однако наложение шифрования не устраняет сетевые ограничения и даже может негативно влиять на производительность TCP: добавляются служебные заголовки, увеличивается время обработки и буферизации пакетов в криптошлюзах [1]. В результате протокол TCP при высоких задержках и потерях пакетов существенно теряет эффективность.

Известно, что в установившемся режиме пропускная способность TCP-соединения при использовании классических алгоритмов управления перегрузкой обратно пропорциональна величине RTT и убывает при росте доли потерь. Согласно модели Матиса, максимальная полезная пропускная способность X для TCP Reno-подобного алгоритма оценивается формулой (1), показывающей резкое падение скорости при увеличении задержки и вероятности потерь [2]:

$$X \approx \sqrt{\frac{3}{2} \frac{MSS}{RTT \sqrt{p}}} \quad (1)$$

где MSS – максимальный размер сегмента;

RTT – время кругового обмена;

p – вероятность потери пакета.

Например, при RTT порядка 600 мс и вероятности потерь $\sim 2\%$ теоретическая пропускная способность классического TCP ограничивается величиной порядка нескольких сотен кбит/с, даже если физический канал имеет пропускную способность в десятки Мбит/с [3]. Таким образом, стандартные алгоритмы (Reno, NewReno, Cubic, Tahoe и др.), основанные на реакциях на потери, не позволяют эффективно использовать канал с большими задержками: после каждого выпадения пакета они существенно снижают окно перегрузки, что приводит к недогрузке канала.

Для смягчения указанных ограничений разработаны новые алгоритмы управления перегрузкой TCP, рассчитанные на сети с большим значением произведения задержки на полосу пропускания. Например, алгоритм TCP Hybla агрессивно увеличивает окно отправки, компенсируя длительный RTT и ускоряя рост окна перегрузки независимо от задержки распространения сигнала [4].

Алгоритм на основе задержки TCP Vegas [5], напротив, использует задержку как индикатор перегрузки: он стремится удерживать минимальную очередь в сети, снижая скорость до уровня, при котором задержка стабилизируется, тем самым почти избегая потерь пакетов.

TCP BBR [6] реализует модельно-ориентированный подход – оценивает доступную полосу пропускания и минимальную задержку канала и устанавливает темп передачи, близкий к пропускной способности, игнорируя отдельные потери.

Алгоритм TCP Cubic представляет собой модификацию NewReno: он использует кубическую функцию времени для увеличения окна после последней перегрузки, что позволяет более эффективно применять доступную полосу в сетях с большим RTT , хотя при частых потерях Cubic также резко снижает скорость передачи [7].

Таким образом, необходимо провести сравнительный анализ перечисленных подходов в условиях, характерных для защищенных каналов связи с высокими задержками и ограниченной полосой пропускания. Подобные условия возникают, например, при использовании VPN-туннелей с шифрованием трафика между удаленными хостами, когда данные передаются через спутниковые или перегруженные наземные каналы.

Исходя из этого, целью настоящего исследования явилось моделирование процесса передачи данных с использованием TCP в подобных каналах, анализ влияния параметров сети и свойств алгоритма TCP на итоговую пропускную способность и надежность передачи информации. В работе исследовалась эффективность различных алгоритмов TCP: Cubic, Hybla, BBR, Vegas как при передаче данных одним, так и несколькими параллельными потоками. Необходимо было найти ответы на следующие вопросы: 1) какой алгоритм лучше приспособлен для работы в защищенных сетях с высокой задержкой, 2) насколько существующие теоретические модели адекватно отражают реальные экспериментальные результаты.

МЕТОДИКА ПРОВЕДЕНИЯ ЭКСПЕРИМЕНТА

Для исследования был развернут экспериментальный стенд, схема которого представлена на рисунке 1.



Рисунок 1 – Схема экспериментального стенда

Клиентское устройство и сервер соединены через два криптомаршрутизатора, образующие VPN-туннель с отечественными алгоритмами шифрования. Между криптошлюзами установлен узел-эмулятор сети (Linux-сервер), позволяющий задать контролируемые сетевые параметры: задержку, потери и ограничение пропускной способности.

Параметры канала связи на эмуляторе были выбраны таким образом, чтобы воспроизвести «тяжелые» условия спутникового канала. С помощью средств утилиты traffic control (модулей netem и tbf) в обоих направлениях были установлены следующие параметры: фиксированная задержка ~300 мс плюс случайный джиттер ± 30 мс (средний $RTT \sim 600$ мс); вероятность случайного отбрасывания пакетов ~2 %; пропускная способность была ограничена на уровне 10 Мбит/с. Буфер очереди в эмуляторе составлял ~500 КБ, что должно было существенно сказаться на пропускной способности канала. Значение 10 Мбит/с было выбрано как типичная полоса пропускания спутникового канала или как результат ограничения провайдером, накладываемого на защищенный канал связи.

Производительность криптомаршрутизаторов достигала ~1 Гбит/с. Таким образом, заданная ограничениями скорость существенно ниже предельного значения пропускной способности канала. Исходя из этого, можно пренебречь влиянием вычислительной мощности шифраторов на пропускную способность и сконцентрироваться на влиянии сетевых факторов и параметров алгоритма TCP.

Для генерации трафика и измерения пропускной способности применялась утилита iperf3 [8]. На стороне клиента данная утилита запускалась в режиме отправителя, на стороне сервера – в режиме приемника. Длительность каждого тестового прогона выбиралась достаточной, чтобы TCP вышел на установившийся режим и сгладил кратковременные флуктуации. По результатам каждого прогона фиксировались: средняя скорость передачи на стороне отправителя, средняя скорость приема на стороне получателя, а также общее число повторных передач за сессию.

В экспериментах сравнивались четыре алгоритма управления перегрузкой TCP:

- *TCP Cubic* – стандартный алгоритм в современных Linux. Относится к методам AIMD (аддитивное увеличение, мультипликативное уменьшение) с более агрессивной функцией роста окна, чем Reno. Эффективнее классических алгоритмов использует каналы с большим RTT и ёмкостью, хотя при высокой частоте потерь также сильно снижает окно передачи;

- *TCP Hybla* – алгоритм, специально разработанный для сетей с большим RTT . Его цель – компенсировать замедленный рост окна при высоких задержках. Для этого в Hybla вводится корректирующий множитель, ускоряющий увеличение окна пропорционально отношению фактического RTT к эталонному значению. В результате Hybla агрессивно наращивает окно передачи, сглаживая разницу между «быстрыми» и «медленными» по задержке соединениями;

- *TCP BBR* – современный алгоритм на основе модели сети. Регулярно измеряет пропускную способность канала и минимальную задержку, поддерживая темп отправки близким к пропускной способности канала. Принципиально не реагирует на отдельные потери пакетов снижением окна, а периодически вводит краткие паузы для контроля очередей и «справедливого» распределения ресурсов. Известно, что BBR v1 может вести себя агрессивно по отношению к классическим потокам TCP, заполняя канал почти полностью;

- *TCP Vegas* – экспериментальный алгоритм, использующий задержку вместо потерь для детекции перегрузки. Стремится удерживать малую очередь в канале, регулируя размер окна так, чтобы RTT оставался близок к базовому значению. Это почти исключает потери, но может приводить к крайне низкому использованию полосы пропускания.

Конкретная модификация используемого алгоритма TCP для каждого теста задавалась через параметры операционной системы перед запуском утилиты iperf3. Для каждого из четырех алгоритмов проводились эксперименты по двум типам сценариев:

- однопоточная передача – запуск одного TCP-соединения от клиента к серверу. Данный режим моделирует ситуацию передачи данных единственной сессией по каналу.

– многопоточная передача – одновременный запуск 5 параллельных TCP-соединений iperf3 между теми же узлами. Суммарный трафик от пяти потоков оценивается совокупно. Этот режим моделирует агрессивное использование канала несколькими параллельными потоками.

Каждый тестовый сценарий повторялся несколько раз для усреднения результатов и исключения влияния случайных факторов. Порядок испытания алгоритмов чередовался, чтобы нивелировать возможный дрейф условий во времени. В итоге для каждого алгоритма в каждом режиме были получены усреднённые значения всех метрик.

РЕЗУЛЬТАТЫ И АНАЛИЗ

Основным показателем эффективности передачи данных служит пропускная способность TCP. Ниже приведены результаты измерений средней скорости приема и среднего числа повторных передач для каждого алгоритма в условиях задержки ~600 мс и потери ~2 % пакетов.

Таблица – Средняя пропускная способность и число повторных передач TCP для различных алгоритмов

Алгоритм TCP	Пропускная способность (1 поток), Мбит/с	Среднее число повторных передач (1 поток)	Пропускная способность (5 потоков), Мбит/с	Среднее число повторных передач (5 потоков)
Vegas	0,303	52,4	1,408	132,6
Cubic	0,651	53,8	2,882	207
Hybla	2,314	1454,2	7,482	9270,7
BBR v1	4,764	2213,6	6,514	3898,8

Одиночный TCP-поток

При передаче по одному TCP-потoku было установлено, что стандартный алгоритм Cubic обеспечивает крайне низкую скорость в заданных условиях – порядка 0,6 Мбит/с, что составляет лишь ~6 % от доступной полосы 10 Мбит/с. Это соответствует теоретической оценке: высокий *RTT* и частые потери не позволяют Cubic «разогнать» окно передачи. После каждой потери Cubic сокращает окно примерно вдвое и затем медленно его увеличивает, но при 2 % потерь сегменты выпадают достаточно часто, не позволяя достичь насыщения канала. В итоге канал используется лишь на малую долю своей емкости. Положительным моментом является то, что Cubic, будучи относительно «осторожным» алгоритмом, генерировал умеренное число повторных передач (~50–60 повторов за сессию), что соответствует потере ~1–2 % пакетов (близко к заданной вероятности потери). Иными словами, Cubic тщательно избегал перегрузки: доля утраченных данных составила около 12 % от отправленного трафика, и алгоритм не допускал лавинообразного роста повторов.

Алгоритм Vegas показал самую низкую скорость среди всех протестированных – около 0,3 Мбит/с (~3 % от емкости канала). Причина заключается в принципе работы Vegas: он активно ограничивает размер окна передачи при росте *RTT*, стараясь минимизировать задержку и избежать потерь. Для канала с *RTT* ~600 мс и пропускной способностью 10 Мбит/с теоретически оптимальный размер окна составляет порядка 0,75 МБ. Однако Vegas намеренно поддерживал окно значительно меньше BDP, чтобы *RTT* оставался близким к базовому. В результате канал практически простаивал (больше 95 % полосы пропускания не использовалось). Потери при работе Vegas минимальны, уровень повторных передач незначителен, порядка десятков пакетов, что подтверждает эффективность алгоритма в предотвращении перегрузки. Тем не менее такой бережный режим оказывается непрактичным: ради нулевых потерь «приносится в жертву» почти весь потенциальный ресурс канала, и скорость передачи недостаточна для большинства задач.

Специализированный под большие задержки алгоритм Hybla в одиночном потоке достиг значительно более высокой пропускной способности – около 2,3 Мбит/с (~23 % от канала). Это почти в 4 раза выше, чем у Cubic, что демонстрирует эффективность подхода Hybla по компенсации длинного *RTT*. Агрессивное наращивание окна позволило оперативно заполнить канал гораздо большим количеством данных. Однако Hybla не реагирует снижением скорости на отдельные потери, продолжая расширять окно даже при их возникновении. Из-за этого за тестовую сессию Hybla сгенерировал очень большое число повторных передач (в среднем около 1400–1500 повторов, что в ~25–30 раз больше, чем у Cubic). Процент потерянных сегментов при одном потоке Hybla достигал ~30 % от общего объема отправленных данных. Тем не менее, несмотря на столь значительные потери, алгоритм продолжал передачу на высокой скорости, практически не снижая окно. Таким образом, Hybla существенно повышает пропускную способность по сравнению с классическими алгоритмами, но достигается это ценой большого числа ретрансмиссий (повторной отправки потерянных или поврежденных пакетов) и заполнения очередей в сети.

Алгоритм BBR продемонстрировал наилучшую скорость при одиночном соединении – около 4,7 Мбит/с, т. е. ~47 % полосы 10 Мбит/с. Это более чем в 7 раз превышает результат Cubic и примерно

в 1,6 раза больше, чем у Hybla. BBR быстро разогнался до скорости, близкой к пропускной способности канала. Однако наличие случайных потерь и ограниченного буфера не позволило достичь полноценных 10 Мбит/с. В отличие от Reno/Cubic, алгоритм BBR не уменьшает окно при потере пакета, но потерянные данные все равно требуют повторной передачи. По измерениям, средняя скорость отправки BBR составила ~5,6 Мбит/с, из которых ~15 % данных терялось (доходило ~4,7 Мбит/с). Общее число повторов у BBR было сопоставимо или даже выше, чем у Hybla (порядка 2200 сегментов за сессию). Это говорит о том, что BBR работал практически на пределе возможностей канала: он заполнял буфер до такой степени, что периодически происходили потери пакетов. Тем не менее алгоритм сохранял высокий темп передачи и не снижал его вследствие потерь. Потери распределялись относительно равномерно и не вызывали таймаутов в течение теста, благодаря чему BBR поддерживал стабильную скорость ~4,7 Мбит/с. Таким образом, BBR обеспечивает компромисс – поддерживает значительно более высокую пропускную способность, чем Cubic, допуская при этом умеренный постоянный уровень потерь (~15 %), но не доводит задержку до экстремальных значений.

Пять параллельных TCP-потоков

При одновременной передаче пяти TCP-потоков суммарная пропускная способность возросла для всех алгоритмов, хотя и в разной степени. В условиях эксперимента 5 потоков разделили между собой фиксированный канал 10 Мбит/с. Теоретически, при идеально справедливом разделении, суммарная скорость не превысила бы возможности одного потока, однако на практике суммарная загрузка канала оказалась выше, чем у одного потока, за счёт особенностей работы алгоритмов и взаимодействия потоков.

Алгоритм Vegas при пяти параллельных соединениях обеспечил суммарно около 1,4 Мбит/с, что почти в 5 раз превышает его скорость в одиночном потоке (0,3 Мбит/с). Фактически каждый поток Vegas стабильно получил ~0,28 Мбит/с, и совместно они заняли ~14 % канала. Такой результат близок к линейному суммированию: потоки Vegas «не мешают» друг другу, работая на одном консервативном уровне. Потери при этом остались очень низкими (~133 повтора суммарно на 5 потоков, то есть каждый поток генерировал не больше нескольких десятков повторных пакетов). Это объясняется тем, что при наличии нескольких потоков Vegas еще быстрее реагирует на рост очереди, удерживая общий уровень загрузки небольшим. Итоговый эффект – практически отсутствие перегрузки, но и совокупная скорость (~1,4 Мбит/с) составила лишь 14 % от доступной полосы, т. е. ~86 % ресурсов канала остались неиспользованными. В прикладном плане даже пять параллельных потоков Vegas не в состоянии эффективно задействовать канал с высокой задержкой, если требуется передавать большие объёмы данных.

Для TCP Cubic добавление параллельных потоков дало более ощутимый прирост суммарной скорости – до ~2,9 Мбит/с (~29 % от канала). Каждый из пяти потоков Cubic в среднем достиг скорости ~0,58 Мбит/с (немного меньше, чем одиночный поток 0,65 Мбит/с). Это указывает на то, что потоки Cubic конкурировали за ресурс: они несколько мешали друг другу, но в то же время совместно лучше заполнили канал, чем один поток. Алгоритм Cubic стремится к справедливому разделению полосы: в отсутствие иных типов трафика несколько Cubic-потоков делят емкость канала поровну. Идеально разделенные 10 Мбит/с дали бы ~2 Мбит/с на поток, в нашем случае из-за потерь и большого *RTT* ни одному потоку не удалось достичь таких величин. Однако асинхронность поведения потоков сыграла положительную роль: когда один поток снижал окно после потери, другие в этот момент могли находиться в фазе роста окна. Благодаря разнесению фаз по времени потоки частично компенсировали просадки друг друга, и канал простаивал меньше, чем при одном потоке. Совокупность пяти «недогруженных» Cubic-потоков обеспечила более равномерное и полное использование пропускной способности канала. Число повторных передач у Cubic возросло пропорционально числу потоков (с ~54 до ~207 суммарно), что соответствует потерям ~20 % от переданных данных. Таким образом, пять параллельных потоков Cubic совместно задействовали около 30 % канала, что все еще значительно меньше общей потенциальной пропускной способности канала.

Алгоритм Hybla при переходе от одного к пяти потокам показал наибольший рост производительности. Суммарная пропускная способность пяти потоков Hybla достигла ~7,5 Мбит/с, что соответствует ~75 % канала. Это втрое выше, чем у одного потока Hybla, и даже превосходит суммарную скорость пяти потоков BBR в тех же условиях. Такой результат обусловлен исключительно агрессивным характером Hybla: все пять потоков интенсивно расширяли окна. 500-КБ буфер на маршрутизаторе постоянно оставался заполненным, и канал работал практически при полной нагрузке. При этом потери пакетов носили массовый и непрерывный характер: общее число повторных передач за тест с пятью потоками Hybla превысило 9000 (против ~1450 при одном потоке). Это существенно больше, чем пятикратный рост. Конкурирующие Hybla-потоки усиливали потери друг друга. Вероятно, синхронное агрессивное увеличение окон всеми потоками приводило к регулярному переполнению буфера, вызывало лавинообразные потери пакетов, после чего все потоки

одновременно снижали окна, затем вновь разгонялись – и цикл повторялся. Несмотря на такой «турбулентный» режим, Nubla устойчиво доставлял данные со скоростью ~7,5 Мбит/с. Интересно, что доля потерь при пяти потоках Nubla оказалась ниже, чем при одном: около 16 % против 30 %. Это можно объяснить тем, что при множественных потоках заполнение буфера было более равномерным во времени и каждое освобождающееся место в очереди сразу же занималось следующими пакетами. Таким образом, параллельные потоки Nubla сумели лучше усреднить загрузку канала, снизив относительный процент потерь, хотя абсолютное число потерянных пакетов было очень велико. Комбинация алгоритма Nubla с многопоточностью позволила максимально приблизиться к полной пропускной способности канала, однако ценой этого стала крайне высокая нагрузка в виде повторных передач. Подобный режим может быть оправдан только в ситуациях, когда приоритетом является максимальный объем переданных данных за минимальное время, а повышенные потери допустимы или компенсируются на нижних уровнях (например, на канальном уровне).

Алгоритм BBR в режиме пяти потоков достиг суммарно около 6,5 Мбит/с (~65 % канала). Это лишь в ~1,37 раза больше, чем у одного потока BBR (4,7 Мбит/с). В отличие от Nubla, где один поток использовал лишь часть канала, однопоточный BBR уже занимал значительную долю полосы, поэтому добавление новых потоков дало не столь значительный прирост. Потоки BBR в эксперименте разделили ресурс относительно равномерно: каждый получил в среднем ~1,3 Мбит/с. Таким образом, конкурируя между собой, ни один поток BBR не смог занять весь канал, и алгоритм реализовал принцип справедливости. Известно, что BBR ограничивает объем данных в сети примерно двойным размером буфера, избегая избыточной очереди. В нашем тесте пять потоков BBR не переполнили буфер так, как это сделали Nubla-потоки, поэтому задержки оставались умеренными. Канал при BBR был загружен лишь на ~65 %, но сдерживание очередей привело к тому, что потери находились на приемлемом уровне: суммарно ~3900 повторов, что соответствует ~29 % утраченных данных. Иными словами, многопоточный BBR действовал осторожнее Nubla: не смог линейно увеличить суммарную скорость с числом потоков и продемонстрировал заметный рост потерь, но в абсолютных цифрах занял второе место по пропускной способности, уступив только Nubla. С практической точки зрения, пять потоков BBR обеспечили значительный объем переданных данных при умеренно высоком уровне потерь, что все же существенно лучше, чем Cubic или Vegas.

ОБСУЖДЕНИЕ

Полученные результаты показывают, что в условиях высоких задержек и потерь выбор алгоритма управления перегрузкой критически влияет на эффективность TCP-соединения. Стандартные алгоритмы (NewReno, Cubic), применяемые по умолчанию, в криптографически защищенном канале с параметрами, типичными для спутниковой связи, недоиспользуют пропускную способность канала. Даже если шифровальное оборудование и физический канал способны поддерживать высокую скорость, классический TCP превращается в «узкое место» транспортного уровня, передавая данные на порядки медленнее возможного. Для задач, связанных с передачей больших объемов информации, такая деградация недопустима.

Альтернативные алгоритмы демонстрируют различные подходы к решению проблемы и имеют свои достоинства и недостатки.

Алгоритм Nubla позволил практически максимально загрузить: в экспериментах Nubla достиг ~75 % пропускной способности при 5 потоках. В закрытых системах с выделенными каналами, где полностью контролируются условия передачи, такой агрессивный подход может быть оправдан – когда нужно любой ценой передать максимальный объем данных за минимальное время. Однако за полный захват полосы Nubla «расплачивается» побочными эффектами. Происходит постоянное переполнение буфера и накопление очереди, что резко увеличивает дополнительную задержку в канале. Для интерактивных сервисов и приложений, чувствительных к времени отклика, это неприемлемо. Также огромное число повторных передач создает дополнительную нагрузку на сеть и конечные устройства. В контексте защищенных каналов это означает лишние зашифрованные пакеты и большой расход трафика. Nubla эффективен для максимального освоения полосы в контролируемом канале, но в общедоступных или совместно используемых сетях столь агрессивная стратегия может вызвать определенные проблемы – задержки и влияние на чужой трафик.

Для практического применения Nubla в защищенных сетях необходимо предусмотреть механизмы смягчения его негативного воздействия. Желательно ограничивать размер очередей на промежуточных узлах и включать активное управление очередью (AQM) или метки ECN, чтобы уменьшить длительность перегрузки. В наших экспериментах AQM не использовался, что позволило Nubla задействовать весь 500-КБ буфер. В реальной сети без AQM это привело бы к росту *RTT* на сотни миллисекунд сверх базового, влияя на все совместно используемые соединения. Таким образом, при внедрении Nubla важно настроить сетевое оборудование таким образом, чтобы минимизировать эффект избыточной буферизации.

Алгоритм BBR показал себя более сдержанным в воздействии на сеть, несмотря на заметную долю повторных передач. BBR целенаправленно ограничивает количество данных, находящихся в процессе передачи по сети, поддерживая его примерно на уровне удвоенного размера буфера. Потери пакетов в наших условиях не были следствием хронической перегрузки – скорость передачи BBR оставалась относительно стабильной, а буфер не переполнялся критически. Алгоритм корректно оценивал параметры канала и поддерживал темп отправки, близкий к оценочной пропускной способности. Отказ снижать скорость при потерях оправдывался тем, что потери воспринимались как не критичные – случайные или происходящие на приемлемом уровне заполнения очереди. BBR добился высоких значений полезной пропускной способности, не создавая гигантских очередей – средняя задержка в канале при использовании BBR значительно ниже, чем при использовании Hubble. Таким образом, BBR достигает компромисса между максимальной производительностью и контролем задержек. Он сознательно не стремится к 100 % загрузке канала, ограничиваясь ~65–70 %, зато избегает эффектов избыточной буферизации. Это особенно важно для защищенных каналов, где передача большого объема данных сопровождается наличием дополнительного служебного трафика.

Следует отметить, что в наших испытаниях BBR проявил себя стабильно и «справедливо» распределил полосу между пятью своими потоками. Однако известны проблемы BBR в других ситуациях: например, при конкуренции с потоками Reno/Cubic он может захватывать непропорционально большую долю полосы, а в условиях резко меняющейся пропускной способности BBR иногда неправильно оценивает параметры и теряет эффективность. В нашем стационарном сценарии таких негативных эффектов не наблюдалось. В будущем, с выходом улучшенной версии BBR v2, ожидается более справедливое поведение и лучшее масштабирование при параллельных потоках. Несмотря на определенные оговорки, уже базовый BBR показал себя перспективным решением для VPN-сетей с высокой задержкой, позволяя существенно повысить скорость передачи без радикальных изменений в информационной инфраструктуре.

Алгоритм Vegas в эксперименте продемонстрировал крайне низкую пропускную способность и, по сути, выступил как противоположность Hubble. Vegas практически устранил потери пакетов, удерживая задержку близкой к базовой, но ценой этого стала неприемлемо малая скорость (3–14 % от канала). Данный результат иллюстрирует предел, на который способен TCP при жестком ограничении перегрузки: потери сведены к нулю, но при этом более 85–95 % ресурса канала простаивает. В реальных условиях Vegas-подход проигрывает при любом сопоставлении с другими модификациями протокола – если по тому же каналу пойдет трафик Cubic или BBR, алгоритм Vegas уступит полосу, так как начнет снижать окно при малейшем росте *RTT*. Таким образом, в гетерогенной сети Vegas неконкурентоспособен и фактически непригоден для обеспечения высокой производительности. Даже в рамках специализированных защищенных каналов использование Vegas нецелесообразно: эффективнее задать ограничение полосы пропускания административно (на уровне QoS), чем полагаться на чрезмерно осторожный TCP-алгоритм. Тем не менее изучение поведения Vegas полезно с научной точки зрения, поскольку демонстрирует крайний вариант стратегии управления перегрузкой – ориентированный на минимизацию потерь и задержек, а не на полосу пропускания.

Практическая значимость результатов состоит в том, что они дают ориентиры для оптимизации защищенных сетей связи. Простейший вывод – необходимо использовать более совершенные алгоритмы, чем стандартный Cubic, если требуется передавать большие объемы данных по каналам с большим *RTT*. При поддержке со стороны сетевого оборудования TCP BBR выглядит предпочтительным выбором в условиях, когда необходимо существенно увеличить скорость VPN-передачи без изменений на уровне приложений. TCP Hubble также показывает высокую скорость и может применяться, если доступна его реализация и сеть является закрытой. В случаях, когда замена алгоритма невозможна, целесообразно прибегнуть к многопоточности на прикладном уровне: как показали опыты, увеличение числа параллельных потоков Cubic с 1 до 5 позволяет почти в пять раз повысить суммарную пропускную способность, частично компенсируя отрицательное влияние высокого *RTT*.

Следует учесть также аспекты информационной безопасности при изменении сетевых параметров. Например, рост интенсивности трафика и числа повторных передач может повысить нагрузку на средства мониторинга – системы обнаружения вторжений (IDS) и анализаторы аномалий. Необычное поведение алгоритмов BBR и Hubble (отсутствие «пилообразного» паттерна у BBR, резкий непрерывный рост окна у Hubble) может не соответствовать заложенному шаблону нормального TCP. Это способно вызвать ложные срабатывания IDS/IPS, которые расценят агрессивный поток ретрансмиссий как атаку. При внедрении новых алгоритмов следует скорректировать профили безопасности, чтобы отличать легитимный высокоинтенсивный трафик от действительно опасных аномалий. Кроме того, важно убедиться, что криптографические шлюзы и конечные серверы способны обрабатывать возросший поток пакетов без снижения эффективности защиты. В противном случае выигрыш в скорости может сопровождаться снижением надежности или безопасности системы.

СРАВНЕНИЕ ЭКСПЕРИМЕНТАЛЬНЫХ ДАННЫХ С ТЕОРЕТИЧЕСКИМИ МОДЕЛЯМИ

Сравнение данных, полученных в экспериментах, с теоретической моделью показало, что простые модели пригодны лишь для первичной оценки скорости передачи данных по TCP в сложных условиях. Реальное поведение современных алгоритмов может существенно отклоняться от предсказаний классических моделей. В наших экспериментах TCP Vegas показал меньшую скорость, чем предсказывает формула Матиса. Напротив, TCP BBR и TCP Hybla превзошли теоретические ограничения классической Reno-модели, поскольку они не реагируют на потери стандартным образом.

Таким образом, при проектировании и настройке защищенных сетей следует учитывать не только теоретические зависимости, но и особенности реализации TCP-алгоритмов в реальных системах.

ЗАКЛЮЧЕНИЕ

В выполненном исследовании проведено моделирование и экспериментальный анализ работы протокола TCP в условиях, характерных для криптографически защищенных каналов связи с высокой задержкой и ограниченной пропускной способностью. На экспериментальном стенде с эмулированными задержками и потерями проанализировано поведение четырех алгоритмов управления перегрузкой: Cubic, Hybla, BBR, Vegas в одиночных и множественных параллельных сессиях передачи данных.

В условиях $RTT \sim 600$ мс и потерь $\sim 2\%$ стандартные алгоритмы (NewReno, Cubic) используют полосу крайне неэффективно: расчетная модель и эксперимент подтвердили падение скорости до <1 Мбит/с при доступных 10 Мбит/с. В тестах одиночный поток Cubic достигал лишь $\sim 0,6$ Мбит/с, что ограничивает возможность передачи больших данных. Специализированные алгоритмы существенно повышают пропускную способность: TCP Hybla – до $\sim 2,3$ Мбит/с (в 3–4 раза выше Cubic) в одиночном потоке, TCP BBR – до $\sim 4,7$ Мбит/с (в 7 раз выше Cubic). При пяти параллельных потоках скорость возросла до $\sim 7,5$ Мбит/с для Hybla и $\sim 6,5$ Мбит/с для BBR (что соответствует освоению $\sim 75\%$ и $\sim 65\%$ канала соответственно).

Таким образом, правильный выбор алгоритма способен на порядок ускорить передачу данных в VPN-сетях с большой задержкой, что критично для приложений, требующих пересылки значительных объемов информации.

Высокая скорость передачи у алгоритмов Hybla и BBR достигается за счет увеличения числа повторных передач. Так, при пяти потоках Hybla генерировала до ~ 9000 повторов в минуту ($\sim 16\%$ потерянных пакетов), а BBR – потерю до $\sim 30\%$ пакетов. Оба алгоритма при этом не снижали резко скорость в ответ на потери, что позволяло им поддерживать высокую полосу пропускания. Cubic и Vegas, напротив, стремились минимизировать потери ($\sim 5\text{--}20\%$ и $<5\%$ соответственно), но ценой значительно меньшей пропускной способности.

Следовательно, выбор алгоритма должен основываться на приоритетах: если канал дорогой и критична экономия ресурса, предпочтительны более умеренные алгоритмы. Если же важнее максимально использовать фиксированную полосу и передать данные быстрее, оправдано применение Hybla или BBR.

Практические рекомендации, вытекающие из работы, заключаются во внедрении современных адаптивных алгоритмов управления перегрузкой в VPN-сетях, работающих в тяжелых условиях. В частности, применение TCP Hybla или BBR позволит в разы повысить скорость передачи данных через зашифрованные каналы с большим RTT по сравнению с Cubic. Если смена алгоритма невозможна, стоит задействовать параллельные TCP-сессии и настроить параметры (размеры окон, ECN/AQM) для лучшего использования канала.

Полученные результаты могут быть использованы при проектировании, оптимизации и эксплуатации защищенных сетей, требующих высокого уровня производительности при сохранении заданного уровня информационной безопасности.

Перспективы дальнейших исследований связаны с изучением смешанных сценариев, анализом поведения в условиях высокодинамичных сетей, а также оценкой влияния самой криптографической обработки и связанных с ней накладных расходов на производительность TCP-соединений. Эти направления позволят углубить понимание работы TCP в защищенных каналах и найти оптимальные решения для различных практических условий.

Список источников

1. Fu, A Generic High-Performance Architecture for VPN Gateways (GHPA) / Fu et al. – 2024.
2. Mathis, M. The macroscopic behavior of the TCP congestion avoidance algorithm / M. Mathis, J. Semke, J. Mahdavi, T. Ott // SIGCOMM Comput. Commun. Rev. – July 1997. – Vol 27, № 3. – P. 67–82. <https://doi.org/10.1145/263932.264023>.
3. Спутниковые системы связи : учебное пособие для вузов / под ред. А. М. Сомова. – Москва : Горячая линия – Телеком, 2012. – 244 с.: ил. – ISBN 978-5-9912-0225-1.
4. Utsumi, S. A new analytical model of TCP Hybla for satellite IP networks / S. Utsumi, S. M. S. Zabir, Y. Usuki, S. Takeda, N. Shiratori, Y. Kato, J. Kim // J. Netw. Comput. Appl. – 2018. – Vol. 124. – P. 137–147.

5. Brakmo, L. S. TCP Vegas: new techniques for congestion detection and avoidance / L. S. Brakmo, S. W. O'Malley, L. L. Peterson // SIGCOMM Comput. Commun. Rev. Oct. 1994. –Vol. 24, № 4. – P. 24–35. <https://doi.org/10.1145/190809.190317>.
6. Cardwell, N. BBR: Congestion-Based Congestion Control / N. Cardwell, Y. Cheng, C. S. Gunn, S. H. Yeganeh, V. Jacobson // ACM Queue. – 2017.
7. Ha, S. CUBIC: A New TCP-Friendly High-Speed TCP Variant / S. Ha, I. Rhee, L. Xu // Proceedings of the ACM SIGOPS/ACM SIGCOMM Workshop on Network-Aware Distributed Applications (NADA). – 2008.
8. iPerf3: утилита для тестирования пропускной способности сети // Wikipedia. – 2024. – URL: <https://ru.wikipedia.org/wiki/Iperf> (дата обращения: 19.07.2025).

References

1. Fu et al. *A Generic High-Performance Architecture for VPN Gateways (GHPA)*, 2024.
2. Mathis, M., Semke, J., Mahdavi, J., Ott, T. The macroscopic behavior of the TCP congestion avoidance algorithm. *SIGCOMM Comput. Commun.*, July 1997, rev. 27, no. 3, pp. 67–82. <https://doi.org/10.1145/263932.264023>.
3. *Satellite Communication Systems : textbook for Universities*. Ed. by A. M. Somov. Moscow, Goryachaya liniya – Telecom, 2012. 244 p.: ill. ISBN 978-5-9912-0225-1 (In Russ.).
4. Utsumi, S., Zabir, S. M. S., Usuki, Y., Takeda, S., Shiratori, N., Kato, Y., Kim, J. A new analytical model of TCP Hybla for satellite IP networks. *J. Netw. Comput. Appl.*, 2018, vol. 124, pp. 137–147.
5. Brakmo, L. S., O'Malley, S. W., Peterson, L. L. TCP Vegas: new techniques for congestion detection and avoidance. *SIGCOMM Comput. Commun. Rev.*, Oct. 1994, vol. 24, no. 4, pp. 24–35. <https://doi.org/10.1145/190809.190317>.
6. Cardwell, N., Cheng, Y., Gunn, C. S., Yeganeh, S. H., Jacobson, V. BBR: Congestion-Based Congestion Control. *ACM Queue*, 2017.
7. Ha, S., Rhee, I., Xu, L. *CUBIC: A New TCP-Friendly High-Speed TCP Variant*. In *Proceedings of the ACM SIGOPS/ACM SIGCOMM Workshop on Network-Aware Distributed Applications (NADA)*, 2008.
8. iPerf3: network throughput testing utility. *Wikipedia*, 2024. URL: <https://ru.wikipedia.org/wiki/Iperf> (accessed 19.07.2025) (In Russ.).

Статья поступила в редакцию 01.09.2025; одобрена после рецензирования 15.09.2025; принята к публикации 22.09.2025.

The article was submitted 01.09.2025; approved after reviewing 15.09.2025; accepted for publication 22.09.2025.

УДК 004.056.5

АНАЛИТИЧЕСКИЙ ОБЗОР ТРЕБОВАНИЙ К СИСТЕМАМ РАЗРАБОТКИ БЕЗОПАСНОГО ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ

Андрусенко Юлия Алексеевна, Северо-Кавказский Федеральный университет, 355017, Российская Федерация, г. Ставрополь, ул. Пушкина, 1,

старший преподаватель, ORCID: 0000-0002-3392-7270 email: yulihka85@mail.ru

Лапин Виталий Геннадьевич, Северо-Кавказский федеральный университет, 355017, Российская Федерация, г. Ставрополь, ул. Пушкина, 1,

кандидат физико-математических наук, доцент, ORCID: 0000-0002-0611-7002, e-mail: vitlx@yandex.ru

Головин Иван Владимирович, Северо-Кавказский федеральный университет, 355017, Российская Федерация, г. Ставрополь, ул. Пушкина, 1,

студент, ORCID: 0009-0008-0512-7242, e-mail: ivangolovin085@gmail.com

Синицын Антон Алексеевич, Институт системного программирования им. В.П. Иванникова РАН, Адрес: 109004, г. Москва, ул. Александра Солженицына, 25,

аспирант, ORCID: 0009-0002-7740-4217 email: antonsinitsyn@outlook.de

В статье проводится аналитический обзор требований к системам разработки безопасного программного обеспечения. Рассмотрены международные стандарты (ISO/IEC 27001, ISO/IEC 27034) и отечественные нормативные документы (ГОСТ, приказы ФСТЭК России), регулирующие процессы создания защищенных программных продуктов. Особое внимание уделено вопросам интеграции безопасности в жизненный цикл программного обеспечения, подходам «Security by Design» и DevSecOps, а также различиям между гибкостью международных моделей и обязательным характером российских требований. Выполнен сравнительный анализ, выявлены совпадающие принципы и ключевые различия, показана специфика нормативно-правового регулирования в России. Сделан вывод о необходимости гармонизации международных и национальных подходов для повышения уровня киберустойчивости и доверия к программным системам.

Ключевые слова: информационная безопасность, безопасное программное обеспечение, жизненный цикл ПО, ISO/IEC 27001, ISO/IEC 27034, ГОСТ, ФСТЭК, Security by Design, DevSecOps

ANALYTICAL REVIEW OF REQUIREMENTS TO SECURE SOFTWARE DEVELOPMENT SYSTEMS

Andrusenko Yulia A., North Caucasus Federal University, 1 Pushkin St., Stavropol, 355017, Russian Federation,

Senior Lecturer, ORCID: 0000-0002-3392-7270, e-mail: yulihka85@mail.ru

Lapin Vitaly G., North Caucasus Federal University, 1 Pushkin St., Stavropol, 355017, Russian Federation, Candidate of Physico-mathematical Sciences, Associate Professor, ORCID: 0000-0002-0611-7002,

e-mail: vitlx@yandex.ru

Golovin Ivan V., North Caucasus Federal University, 1 Pushkin St., Stavropol, 355017, Russian Federation, Student, ORCID: 0009-0008-0512-7242, e-mail: ivangolovin085@gmail.com

Sinitsyn Anton A., Institute of System Programming named after V.P. Ivannikov of RAS, 25 Alexander Solzhenitsyn St., Moscow, 109004, Russian Federation,

graduate student, ORCID: 0009-0002-7740-4217, e-mail: antonsinitsyn@outlook.de

This article provides an analytical review of requirements for secure software development systems. It examines international standards (ISO/IEC 27001, ISO/IEC 27034) and domestic regulations (GOST, FSTEC of Russia orders) governing the development of secure software products. Particular attention is paid to integrating security into the software lifecycle, the Security by Design and DevSecOps approaches, and the differences between the flexibility of international models and the mandatory nature of Russian requirements. A comparative analysis is conducted, identifying common principles and key differences, and highlighting the specifics of regulatory frameworks in Russia. It concludes that harmonizing international and national approaches is essential to increasing cyber resilience and trust in software systems.

Keywords: information security, secure software, software life cycle, ISO/IEC 27001, ISO/IEC 27034, GOST, FSTEC, Security by Design, DevSecOps

ВВЕДЕНИЕ

Современные программные системы являются не просто инструментами автоматизации – они превратились в критически важные элементы цифровой инфраструктуры государства, бизнеса и общества. От устойчивости и защищенности программного обеспечения сегодня напрямую зависят национальная безопасность, конкурентоспособность организаций и доверие пользователей. Однако именно разработка безопасного программного обеспечения остается одним из самых уязвимых

и противоречивых звеньев в цепочке обеспечения информационной безопасности. Поэтому вопросы стандартизации и формализации требований к процессам разработки программного обеспечения выходят на первый план, становясь стратегическим фактором киберустойчивости. Из исследования, проведенного компанией IBM «Cost of a Data Breach» – одного из крупнейших поставщиков программного обеспечения в мире, мы знаем, что средняя стоимость утечки данных для компании в мире составляет 4,44 миллиона долларов [1].

На международном уровне накоплен значительный опыт в этой области: стандарты ISO/IEC 27001, ISO/IEC 27034, практики NIST и OWASP задают рамки для построения зрелых процессов безопасной разработки. В то же время в России действует собственная нормативная база – ГОСТы, приказы ФСТЭК, методические документы Банка России, – ориентированная прежде всего на защиту критической информации и выполнение требований регуляторов. Эти два подхода – зарубежный и отечественный – во многом пересекаются, но также имеют заметные различия, продиктованные как особенностями правовой системы, так и спецификой национальной киберугрозы.

Цель настоящей статьи – провести аналитический обзор требований к системам разработки безопасного программного обеспечения, выявить общие и различающиеся черты в российских и зарубежных стандартах, а также оценить перспективы их гармонизации. Подобный сравнительный анализ представляется актуальным не только с научной, но и с практической точки зрения: он позволяет сформировать целостное понимание, каким образом можно адаптировать лучшие мировые практики к отечественным условиям и одновременно повысить эффективность национальной нормативной системы.

ПРОБЛЕМАТИКА БЕЗОПАСНОСТИ В ЖИЗНЕННОМ ЦИКЛЕ ПО

Разработка программного обеспечения традиционно воспринималась как процесс, в котором приоритет отдавался функциональности, удобству использования и скорости выхода продукта на рынок. Вопросы же безопасности зачастую рассматривались на второстепенных этапах – как дополнительные «надстройки» или набор технических мер, которые можно внедрить уже после того, как система создана. Подобный подход исторически приводил к тому, что уязвимости закладывались в основу продукта еще на стадии его проектирования и разработки, становясь латентной угрозой на протяжении всего жизненного цикла. Исходя из уже упомянутого исследования IBM, лишь 49 % компаний инвестируют больше средств в кибербезопасность после утечки данных [1]. Хотя еще в работе «Software Engineering Economics» за авторством Barry William Boehm – американского специалиста по экономике ПО, написанной в 1981, указывается, что с экономической точки зрения уязвимостей – часто системного характера – легче избежать на ранних фазах проектирования, чем устранять их позднее, что поддерживает классические выводы о росте стоимости исправления дефектов по мере продвижения по жизненному циклу разработки [2].

В научной и практической плоскости жизненный цикл ПО описывается как последовательность фаз: определение требований, проектирование, реализация, тестирование, внедрение, сопровождение и вывод из эксплуатации. Каждая из этих фаз сопряжена со своими специфическими рисками. На этапе формулирования требований отсутствует четкая фиксация параметров безопасности: функциональные ожидания клиента преобладают над требованиями к конфиденциальности, целостности и доступности данных. В результате безопасность зачастую формулируется в общих словах («должна быть обеспечена защита данных»), не превращаясь в конкретные технические или организационные критерии.

Этап проектирования связан с формированием архитектуры системы, и именно здесь ошибки приобретают стратегический характер. Непродуманный выбор архитектурных паттернов, отсутствие моделей угроз, недооценка рисков интеграции с внешними сервисами могут обернуться тем, что безопасность оказывается не встроенной в систему, а лишь «прикрепленной» к ней в виде отдельных компонентов. Мировая практика показывает: чем позже обнаруживается дефект проектного уровня, тем дороже обходится его устранение.

Следует подчеркнуть, что проблематика безопасности в жизненном цикле ПО носит системный характер. Она не сводится к отдельным ошибкам разработчиков или тестировщиков, а отражает общий уровень зрелости процессов. Современные исследования подтверждают: компании, внедряющие практики «Security by Design» и DevSecOps, снижают совокупную стоимость владения и управления рисками, поскольку безопасность интегрируется на всех этапах – от формулировки требований до эксплуатации. Тем не менее, массовое распространение таких подходов сталкивается с организационными барьерами: недостатком компетенций специалистов, отсутствием стимулов у бизнеса вкладываться в долгосрочную безопасность, а также конфликтом между скоростью разработки и глубиной контроля.

Таким образом, проблематика безопасности в жизненном цикле ПО проявляется как на уровне технологий, так и на уровне управления. Наличие формальных стандартов и методик (ISO/IEC 27034, NIST SSDF, OWASP SAMM) демонстрирует зрелый подход международного сообщества,

где безопасность рассматривается как неотъемлемый атрибут качества программного продукта. Однако без институционального закрепления этих требований и без их интеграции в организационные процессы риск сохранения «порочной практики» – когда безопасность воспринимается как второстепенный аспект – остаётся чрезвычайно высоким.

ЗАРУБЕЖНЫЕ СТАНДАРТЫ И ПРАКТИКИ

Мировая практика обеспечения безопасности программного обеспечения в последние десятилетия формировалась вокруг системы международных стандартов ISO/IEC. Именно они задали универсальную рамку, которая позволяет организациям любых отраслей и масштабов выстраивать процессы разработки с учетом требований информационной безопасности. Среди всей серии ключевое значение имеют два документа – ISO/IEC 27001 и ISO/IEC 27034. Первый определяет основы построения системы управления информационной безопасностью (СУИБ), а второй – акцентирует внимание на особенностях безопасности приложений и интеграции соответствующих механизмов в жизненный цикл ПО. В официальной документации ISO/IEC 27001:2022 прописано, что «ISO/IEC 27001 задает управленческую рамку (PDCA) для СУИБ, тогда как ISO/IEC 27034 детализирует рекомендации по интеграции безопасности именно в жизненный цикл приложений – от спецификации требований до процедур верификации» [3].

Стандарт ISO/IEC 27001 в течение многих лет воспринимается как «золотой стандарт» управления информационной безопасностью. Его значение выходит далеко за рамки сугубо технических регламентов: это управленческая модель, которая внедряет культуру безопасности на уровне всей организации. Основой ISO/IEC 27001 является процессный подход и цикл непрерывного совершенствования PDCA (Plan-Do-Check-Act), позволяющий системно интегрировать управление безопасностью в корпоративную стратегию.

Применительно к разработке ПО данный стандарт играет роль методологического каркаса. Он не предписывает конкретные алгоритмы программирования или тестирования, но задает контекст, в котором должны формироваться требования к продукту. На стадии планирования организация обязана учитывать информационные риски, связанные с созданием и эксплуатацией программных систем. Это предполагает формализацию политики безопасности, идентификацию угроз и уязвимостей, определение допустимых уровней риска.

В фазе «Do» реализуются меры защиты, которые включают как организационные, так и технические аспекты: регламентацию процессов проектирования, контроль доступа к исходному коду, использование криптографических методов, управление инцидентами. Этап «Check» предполагает проведение аудитов, тестирования безопасности и анализа эффективности внедрённых мер, а «Act» – их корректировку в соответствии с новыми рисками и изменяющейся архитектурой системы, что иллюстрирует рисунок.

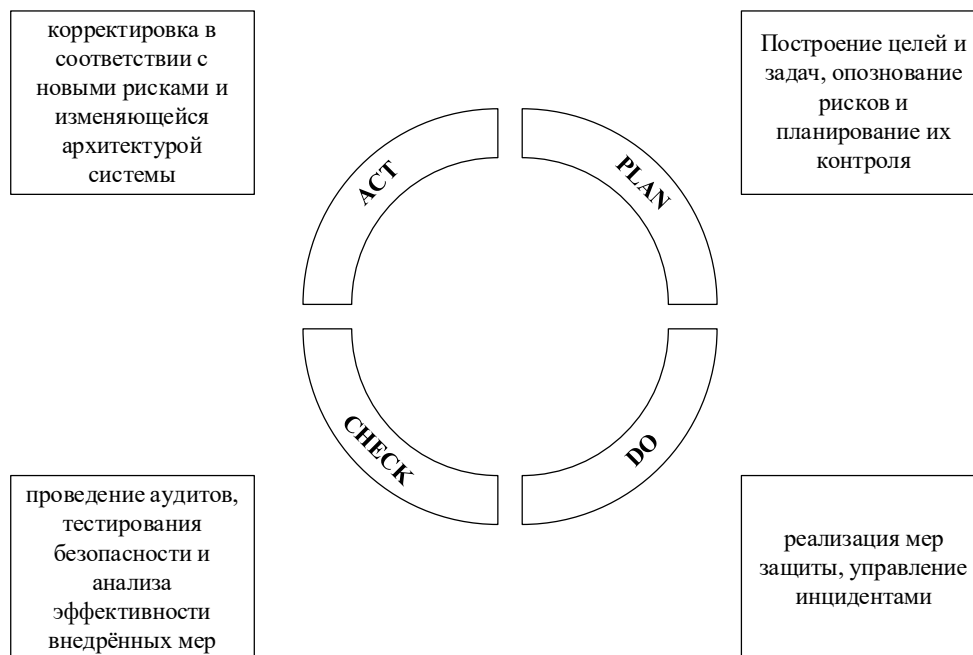


Рисунок – Подход и цикл непрерывного совершенствования PDCA (Plan-Do-Check-Act)

Таким образом, ISO/IEC 27001 создает управленческую «надстройку», которая делает процесс разработки безопасного ПО прозрачным, контролируемым и воспроизводимым. Важно отметить, что сертификация по этому стандарту сегодня выступает конкурентным преимуществом: она не только демонстрирует зрелость организации, но и служит гарантом доверия для заказчиков и партнеров.

Если ISO/IEC 27001 можно назвать управленческим фундаментом, то ISO/IEC 27034 представляет собой логическое продолжение в прикладной области. Этот стандарт фокусируется на безопасности приложений, трактуя ее как неотъемлемый элемент жизненного цикла программного обеспечения. Он впервые систематизировал требования к тому, как именно интегрировать защитные механизмы в процессы анализа, проектирования, реализации и тестирования.

Ключевым понятием в ISO/IEC 27034 является Application Security Control (ASC) - набор организационных, технических и процессных мер, встроенных в приложение на разных этапах его разработки. В отличие от традиционного подхода, когда безопасность проверяется на выходе, ISO/IEC 27034 настаивает на раннем и последовательном включении этих мер. Например, уже на этапе анализа требований формируются спецификации безопасности, которые затем транслируются в архитектурные решения. На стадии кодирования это выражается в использовании защищенных библиотек, правил безопасного программирования, методов статического анализа кода.

Стандарт также предлагает понятие Application Security Management Process (ASMP) – процесса управления безопасностью приложений, который должен быть интегрирован в корпоративную систему управления информационной безопасностью (СУИБ), описанную в ISO/IEC 27001. Это создает синергию: стратегические цели безопасности на уровне организации превращаются в конкретные меры на уровне программных продуктов.

Особое внимание ISO/IEC 27034 уделяет вопросам валидации и верификации. Стандарт предлагает методы систематического тестирования, включая моделирование атак, анализ исходного кода, а также контроль исполнения приложений в реальных условиях. В результате создается не просто функционально корректное ПО, но система, устойчивость которой подтверждена объективными процедурами контроля.

Совместное использование ISO/IEC 27001 и ISO/IEC 27034 формирует основу концепции «Security by Design», когда безопасность не навязывается продукту извне, а встраивается в его «генетический код». Этот подход отражает эволюцию взглядов на программную инженерию: от идеи, что безопасность можно «добавить» на этапе тестирования, к пониманию ее как фундаментального свойства архитектуры и процессов.

С практической точки зрения стандарты дают организациям универсальный язык и набор инструментов для выстраивания процессов. Независимо от отрасли – будь то финансы, здравоохранение или промышленность – компании сталкиваются с общими угрозами: кражей данных, вредоносными атаками, нарушением целостности систем. Использование международных стандартов позволяет унифицировать требования, облегчает взаимодействие с партнерами и повышает прозрачность процессов сертификации.

Важно и то, что стандарты ISO/IEC отражают идею гибкости и адаптивности. Они не являются жесткими регламентами, а выступают рамочной моделью, которую каждая организация адаптирует под собственные риски, ресурсы и стратегические цели. Именно в этом заключается их научная и практическая ценность: стандарты задают не конечный результат, а путь, позволяющий организациям развиваться в сторону зрелости и устойчивости.

РОССИЙСКИЕ СТАНДАРТЫ И НОРМАТИВНЫЕ ТРЕБОВАНИЯ

Становление практики разработки безопасного программного обеспечения в России во многом определяется национальной системой стандартизации и действующей нормативно-правовой базой в области защиты информации. В отличие от международных моделей, ориентированных преимущественно на процессный и методический подход, российские документы изначально развивались как инструмент правового регулирования и сертификационной практики. Такой подход обусловлен особенностями национальной киберугрозы, а также высоким приоритетом задач защиты государственной тайны и критически важной информации.

Ключевую роль в формировании нормативных требований играют государственные стандарты (ГОСТы). В отечественной системе особое значение имеют адаптированные международные документы, например ГОСТ Р ИСО/МЭК 15408 – российский эквивалент стандарта Common Criteria. Этот документ регламентирует принципы оценки безопасности информационных технологий, включая программное обеспечение. Он задает модель, в рамках которой разработчик обязан определить профили защиты, сформулировать цели безопасности и продемонстрировать, каким образом архитектура продукта обеспечивает выполнение этих целей.

ГОСТ Р ИСО/МЭК 15408 фактически вводит формализованный язык описания требований безопасности и средств их реализации. Это приближает российскую практику к международной,

но при этом вносит собственную специфику: акцент на документированности процессов и возможности независимой сертификации. Для разработчика это означает необходимость не только технически внедрять защитные механизмы, но и подтверждать их эффективность через формальные процедуры оценки.

Помимо ГОСТ Р ИСО/МЭК 15408, значимыми являются стандарты серии 27XXX, где рассматриваются аспекты управления информационной безопасностью и взаимодействия организационных и технических мер. Хотя эти стандарты частично гармонизированы с ISO/IEC 27000, их практическая реализация в России тесно связана с требованиями регуляторов и национальными методическими документами.

Таким образом, российские ГОСТы задают двойную рамку: с одной стороны, они обеспечивают совместимость с международными подходами, а с другой – закрепляют необходимость соответствия специфическим государственным требованиям. Это делает их не только инструментом технической унификации, но и частью правового механизма обеспечения безопасности.

Центральным актором в сфере регулирования разработки защищенного программного обеспечения в России выступает Федеральная служба по техническому и экспортному контролю (ФСТЭК). Ее приказы формируют обязательные требования к разработчикам, производителям и эксплуатирующим организациям, создавая национальную специфику, которая отличает российскую модель от зарубежных.

Особое значение имеет Приказ ФСТЭК № 17 «О защите информации, не составляющей государственную тайну, содержащейся в государственных информационных системах». Этот документ задает уровни защищенности, определяет минимальные меры защиты, а также предъявляет требования к программному обеспечению, которое функционирует в составе государственных систем. Для разработчиков это означает необходимость учитывать классификацию информационных систем по уровням значимости и обеспечивать соответствующий набор защитных функций.

Не менее важен Приказ ФСТЭК № 239, устанавливающий порядок сертификации средств защиты информации. В его рамках программные продукты рассматриваются как объекты, которые должны пройти независимую оценку на соответствие требованиям безопасности. Такая сертификационная модель предполагает, что разработчик обязан предоставить документацию, описывающую архитектуру, процессы разработки, результаты тестирования и подтверждающую устойчивость к заданному классу угроз.

Регуляторная практика ФСТЭК ориентирована не только на обеспечение базовой защищенности, но и на создание механизма доверия между государством, бизнесом и конечными пользователями. Сертифицированное программное обеспечение признается надёжным и может применяться в системах, где обработка информации имеет критическую значимость. Тем самым формируется национальный рынок безопасного ПО, на котором фактор соответствия нормативным требованиям становится не менее важным, чем технические характеристики продукта.

Следует подчеркнуть, что российские приказы и методические документы носят обязательный характер для государственных структур и организаций, работающих с конфиденциальной или критически важной информацией. Это существенно отличает их от международных стандартов ISO/IEC, которые имеют рекомендательный статус и приобретают силу через добровольную сертификацию. В российской практике несоблюдение нормативных требований влечет административную и юридическую ответственность, что делает вопросы безопасности не факультативными, а встроенными в саму логику функционирования информационных систем.

В совокупности ГОСТы и приказы ФСТЭК создают многоуровневую систему, в которой процессы разработки программного обеспечения неразрывно связаны с задачами информационной безопасности. ГОСТы обеспечивают методологическую основу и возможность гармонизации с международной практикой, тогда как приказы формируют жесткую правовую рамку, регулиующую обязательные меры и процедуры. Таблица 1 показывает основные ГОСТы, регулирующие требования к информационной безопасности.

Для разработчиков это означает необходимость учитывать одновременно два аспекта: международную совместимость и национальное соответствие. С одной стороны, продукт должен быть конкурентоспособным на глобальном рынке и соответствовать ISO/IEC 27000 или Common Criteria, с другой - он обязан удовлетворять конкретным требованиям российских регуляторов. Этот дуализм задаёт особый контекст российской практики: безопасность рассматривается не только как технический атрибут качества, но и как юридическая обязанность, закреплённая на уровне государства.

Таблица 1 – Межгосударственные стандарты РФ в области ИБ

Название ГОСТ	Что внедряет / требования
ГОСТ Р 57580.1-2017	Общие требования к системе управления информационной безопасностью (СУИБ)
ГОСТ Р 57580.2-2017	Требования к управлению рисками информационной безопасности
ГОСТ Р 58442-2019	Требования к защите персональных данных в информационных системах
ГОСТ Р ИСО/МЭК 27001-2013	Требования к системе менеджмента информационной безопасности (ISMS)
ГОСТ Р 56939-2016	Методы оценки защищённости объектов информационной инфраструктуры
ГОСТ Р 50571.16-2016	Требования к кибербезопасности объектов промышленной автоматизации
ГОСТ Р 57580.3-2018	Требования к аудиту и контролю системы информационной безопасности
ГОСТ Р 53659-2009	Требования к криптографической защите информации
ГОСТ Р 50922-96	Общие требования к обеспечению безопасности сетей передачи данных

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ПОДХОДОВ

При рассмотрении требований к разработке безопасного программного обеспечения сквозь призму международных и отечественных стандартов выявляется как сходство в исходных принципах, так и серьёзные различия в методах их практической реализации. Этот дуализм наглядно проявляется в трёх ключевых плоскостях: общих ценностях и целях, уровне детализации требований и характере интеграции безопасности в жизненный цикл разработки.

И международные, и российские стандарты едины в понимании того, что безопасность ПО должна строиться вокруг трёх классических постулатов – конфиденциальности, целостности и доступности информации. Более того, оба подхода опираются на риск-ориентированную методологию, подразумевающую необходимость идентификации угроз и их соотнесения с допустимыми уровнями риска. В этом смысле наблюдается ценностное и понятийное единство: ни один стандарт не рассматривает безопасность как набор случайных мер, напротив, в центре внимания всегда стоит системный анализ и управление рисками.

Заметные расхождения проявляются в том, как именно фиксируются и описываются требования. Международные стандарты ISO/IEC 27001 и 27034 формулируют их в форме процессных рамок: организация получает свободу в выборе конкретных методов и инструментов, но обязана следовать общей логике цикла PDCA и встраивать защитные механизмы на каждом этапе. Российские же нормативные документы, напротив, более жестко задают содержание мер: ГОСТ Р ИСО/МЭК 15408 требует определённого уровня детализации профилей защиты, а приказы ФСТЭК предписывают обязательные меры и процедуры. Таким образом, международный подход ориентирован на гибкость и адаптацию, тогда как отечественный – на нормативность и унификацию.

Наконец, различия особенно ощутимы в том, каким образом безопасность встраивается в процесс разработки. В международной практике она интегрируется в жизненный цикл ПО как органическая часть методологии – начиная с анализа требований и заканчивая сопровождением. ISO/IEC 27034 подчеркивает необходимость формулирования и реализации требований безопасности на каждом этапе, создавая эффект «Security by Design». В российской же модели безопасность зачастую привязывается к итоговой сертификации и соответствию предписанным уровням защищённости. Это не исключает интеграции в процесс, но смещает акцент: внимание концентрируется на документировании мер и подтверждении их соблюдения в рамках проверок и аудитов.

Таблица 2 – Сравнение международных и российских стандартов

Критерий	Международные стандарты (ISO/IEC 27001, 27034)	Российские стандарты и приказы (ГОСТ, ФСТЭК)
Базовые принципы	Конфиденциальность, целостность, доступность; риск-ориентированность	Конфиденциальность, целостность, доступность; риск-ориентированность
Характер требований	Процессные, рамочные, гибкие; адаптируемые под специфику организации	Нормативно-правовые, обязательные; детализированные и унифицированные
Фокус на жизненном цикле	Интеграция безопасности на всех этапах разработки («Security by Design»)	Основной акцент на итоговой сертификации и подтверждении мер защиты
Документирование	Рекомендуемое, адаптивное; ориентировано на внутренние процессы	Жестко регламентированное; обязательное для сертификации
Гибкость применения	Высокая: организация сама выбирает методы в пределах рамок стандарта	Низкая: строгое следование предписанным требованиям

В таблице 2 можно заметить, что различия не сводятся к «лучше – хуже», а отражают разные исторические и институциональные контексты. Международная модель формировалась как инструмент универсализации и добровольной сертификации, в то время как российская – как часть государственной системы регулирования и защиты критической информации.

ЗАКЛЮЧЕНИЕ

Проведенный анализ продемонстрировал, что российские и международные стандарты исходят из единой аксиоматики безопасности – необходимости обеспечения конфиденциальности, целостности и доступности информации на всех стадиях жизненного цикла программного обеспечения. Однако практические подходы к реализации этих принципов заметно различаются. Международная практика (ISO/IEC 27001, ISO/IEC 27034) акцентирует внимание на процессах, управленческих механизмах и гибкой адаптации мер к контексту организации. Российская нормативная база (ГОСТ Р ИСО/МЭК 15408, приказы ФСТЭК) сосредоточена на обязательных мерах, формализованной документированности и сертификационной проверке соответствия.

Эти различия нельзя оценивать в категориях «правильного» или «ошибочного» подхода. Они отражают специфику институциональной среды: международные стандарты призваны гармонизировать практику в условиях разнообразных экономик и правовых систем, а российские нормативные акты – гарантировать защиту информации в условиях государственного регулирования и особого значения критической инфраструктуры. В этой двойственности и заключается главный вызов: найти баланс между гибкостью и нормативностью, между адаптивностью процессов и строгим контролем.

Таблица 3 – Итоги анализа

Критерий анализа	Международные стандарты (ISO/IEC 27001, 27034)	Российские стандарты и приказы (ГОСТ, ФСТЭК)
Целевые принципы	Конфиденциальность, целостность, доступность; риск-ориентированность	Конфиденциальность, целостность, доступность; риск-ориентированность
Механизм реализации	Процессный подход, гибкая адаптация, PDCA	Нормативные предписания, обязательность, формализованность
Интеграция в жизненный цикл	Security by Design, непрерывность на всех этапах	Акцент на итоговой сертификации и документировании
Роль сертификации	Добровольная, демонстрация зрелости и доверия	Обязательная, условие функционирования в критичных системах
Перспектива сотрудничества	Гармонизация и признание сертификаций в глобальном масштабе	Необходимость адаптации и интеграции в международный контекст

Исходя из представленного в таблице 3 и вышеизложенного, понятно, что сравнительный анализ показывает, что ключ к повышению безопасности программного обеспечения лежит не в противопоставлении международного и российского подходов, а в их взаимном дополнении. Использование гибкости ISO и строгости национальных норм может обеспечить более комплексный результат, где каждая из сторон привносит свои сильные стороны. В будущем именно международное сотрудничество и интеграция сертификационных практик способны стать той площадкой, где произойдет синтез лучших решений с целью формирования по-настоящему устойчивой и безопасной цифровой среды.

Список источников

1. IBM. Cost of a Data Breach Report 2025. – URL: <https://www.ibm.com/reports/data-breach>.
2. Barry, William Boehm. Software Engineering Economics / Barry William Boehm. – Englewood Cliffs: Prentice-Hall, 1981. – URL: <https://staff.emu.edu.tr/alexanderchefranov/Documents/CMPE412/Boehm1981%20COCOMO.pdf>.
3. ISO/IEC 27001:2022. Information security, cybersecurity and privacy protection – Information security management systems – Requirements. – URL: <https://www.iso.org/standard/27001>.
4. Anderson, R. Why information security is hard – an economic perspective / R. Anderson // Proceedings of the 17th Annual Computer Security Applications Conference (ACSAC). – 2001. – URL: <https://www.acsac.org/2001/papers/110.pdf>.
5. Howard, M. The Security Development Lifecycle / M. Howard, S. Lipner. – Microsoft Press, 2006. – URL: https://download.microsoft.com/download/8/1/6/816C597A-5592-4867-A0A6-A0181703CD59/Microsoft_Press_eBook_TheSecurityDevelopmentLifecycle_PDF.pdf.
6. IBM Security; Ponemon Institute. Cost of a Data Breach Report 2023. – URL: <https://dl10erj175o600.cloudfront.net/.../Cost-of-a-Data-Breach-Report-2023.pdf>.
7. ISO/IEC 27001:2013. Information security management systems – Requirements. – URL: <https://www.iso.org/standard/54534.html>.
8. ISO/IEC 27034. Application security (parts). – URL: <https://www.iso.org/standard/44378.html>.

9. Яриков, В. Г. Методы разработки защищённого программного обеспечения / В. Г. Яриков, М. В. Пашков // Информ. безопасность и связь. – 2023. – URL: <https://cyberleninka.ru/article/n/metody-razrabotki-zaschisshennogo-programmnogo-obespecheniya-1>.
10. Барабанов, А. В. Нормативные вопросы безопасного производства программ / А. В. Барабанов // Вопросы стандартизации и защиты информации. – 2013. – URL: <https://cyberleninka.ru/article/n/normativnye-voprosy-bezopasnogo-proizvodstva-programm>.
11. Волошин, И. П. Безопасность при разработке программного обеспечения / И. П. Волошин // Информационная безопасность. – 2018. – URL: <https://cyberleninka.ru/article/n/bezopasnost-pri-razrabotke-programmnogo-obespecheniya>.
12. Кириллов, А. Л. Постановка задачи оценки информационной безопасности сложных информационно-технических систем / А. Л. Кириллов // Информационная безопасность. – 2006. – URL: <https://cyberleninka.ru/article/n/postanovka-zadachi-otsenki-informatsionnoy-bezopasnosti-slozhnyh-informatsionno-tehnicheskikh-sistem>.
13. ГОСТ Р 71206–2024. Защита информации. Разработка безопасного программного обеспечения. Безопасный компилятор языков C/C++. Общие требования. – URL: <https://protect.gost.ru/document.aspx?control=7&id=257755>.
14. Черемисин, Д. Г. Безопасная разработка программного обеспечения / Д. Г. Черемисин, В. Р. Мкртчян // Символ науки. – 2023. – URL: <https://cyberleninka.ru/article/n/bezopasnaya-razrabotka-programmnogo-obespecheniya>.
15. Юлдашев, Т. З. Основы информационной безопасности при разработке сайтов / Т. З. Юлдашев, С. А. Шептунов // Инфокоммуникационные технологии. – 2018. – Т. 16, № 4. – С. 430–437. – DOI 10.18469/ikt.2018.16.4.10. – URL: <https://journals.eco-vector.com/2073-3909/article/view/56447>.

References

1. IBM. *Cost of a Data Breach Report 2025*. Available at: <https://www.ibm.com/reports/data-breach>.
2. Boehm, Barry William. *Software Engineering Economics*. Englewood Cliffs: Prentice-Hall, 1981. Available at: <https://staff.emu.edu.tr/alexanderchEFRANOV/Documents/CMPE412/Boehm1981%20COCOMO.pdf>.
3. ISO/IEC 27001:2022. *Information security, cybersecurity and privacy protection – Information security management systems – Requirements*. Available at: <https://www.iso.org/standard/27001>.
4. Anderson, R. Why information security is hard – an economic perspective. *Proceedings of the 17th Annual Computer Security Applications Conference (ACSAC)*, 2001. Available at: <https://www.acsac.org/2001/papers/110.pdf>.
5. Howard, M., Lipner, S. *The Security Development Lifecycle*. Microsoft Press, 2006. Available at: https://download.microsoft.com/download/8/1/6/816C597A-5592-4867-A0A6-A0181703CD59/Microsoft_Press_eBook_TheSecurityDevelopmentLifecycle_PDF.pdf.
6. IBM Security; Ponemon Institute. *Cost of a Data Breach Report 2023*. Available at: <https://d110erj175o600.cloudfront.net/.../Cost-of-a-Data-Breach-Report-2023.pdf>.
7. ISO/IEC 27001:2013. *Information security management systems – Requirements*. Available at: <https://www.iso.org/standard/54534.html>.
8. ISO/IEC 27034. *Application security (parts)*. Available at: <https://www.iso.org/standard/44378.html>.
9. Yarikov, V. G., Pashkov, M. V. Methods of Secure Software Development. *Information Security and Communications*, 2023. Available at: <https://cyberleninka.ru/article/n/metody-razrabotki-zaschisshennogo-programmnogo-obespecheniya-1> (In Russ.).
10. Barabanov, A. V. Regulatory Issues of Secure Software Production. *Questions of Standardization and Information Security*, 2013. Available at: <https://cyberleninka.ru/article/n/normativnye-voprosy-bezopasnogo-proizvodstva-programm> (In Russ.).
11. Voloshin, I. P. Security in Software Development. *Information Security*, 2018. Available at: <https://cyberleninka.ru/article/n/bezopasnost-pri-razrabotke-programmnogo-obespecheniya> (In Russ.).
12. Kirillov, A. L. Formulation of the Task of Assessing Information Security of Complex Information-Technical Systems. *Information Security*, 2006. Available at: <https://cyberleninka.ru/article/n/postanovka-zadachi-otsenki-informatsionnoy-bezopasnosti-slozhnyh-informatsionno-tehnicheskikh-sist.em> (In Russ.).
13. GOST R 71206–2024. *Information Protection. Secure Software Development. Safe Compiler of C/C++ Languages. General Requirements*. Available at: <https://protect.gost.ru/document.aspx?control=7&id=257755> (In Russ.).
14. Cheremisin, D. G., Mkrтчян, V. R. Secure Software Development. *Symbol of Science*, 2023. Available at: <https://cyberleninka.ru/article/n/bezopasnaya-razrabotka-programmnogo-obespecheniya> (In Russ.).
15. Yuldashev, T. Z., Sheptunov, S. A. Fundamentals of Information Security in Website Development. *Information Communication Technologies*, 2018, vol. 16, no. 4. pp. 430–437. DOI 10.18469/ikt.2018.16.4.10. Available at: <https://journals.eco-vector.com/2073-3909/article/view/56447> (In Russ.).

Статья поступила в редакцию 05.09.2025; одобрена после рецензирования 16.09.2025; принята к публикации 30.09.2025.

The article was submitted 05.09.2025; approved after reviewing 16.09.2025; accepted for publication 30.09.2025.

УДК 519.651

АЛГОРИТМЫ ВЫЧИСЛЕНИЯ ФУНКЦИЙ ОТ ОДНОЙ ПЕРЕМЕННОЙ ДЛЯ ОБРАБОТКИ ЗАШИФРОВАННЫХ ЧИСЕЛ В РАСПРЕДЕЛЕННЫХ СРЕДАХ

Лапина Мария Анатольевна, Северо-Кавказский федеральный университет, 355002, Российская Федерация, г. Ставрополь, ул. Пушкина, 1,
кандидат физико-математических наук, доцент, ORCID: 0000-0001-8117-9142, e-mail: mlapina@ncfu.ru

Криволапова Ольга Владимировна, Северо-Кавказский федеральный университет, Российская Федерация, 355017, г. Ставрополь, ул. Пушкина, 1,
аспирант, e-mail: obabchenko@ncfu.ru

Хамидов Мухаммаджон Рустамович, Северо-Кавказский федеральный университет, Российская Федерация, 355017, г. Ставрополь, ул. Пушкина, 1,
аспирант, e-mail: hamidovmuhammad36@gmail.com

Бесаева Зарина Вячеславовна, Юго-Осетинский государственный университет имени А. А. Тибилова, Республика Южная Осетия, 100001, г. Цхинвал, ул. Путина (бывшая ул. Московская), 8,
соискатель ученой степени кандидата наук

В процессе решения многих практических задач возникает необходимость исследовать функциональные зависимости между величинами, которые приближенно или точно выражаются с помощью элементарных функций. Вычисление значений элементарных функций – наиболее часто встречающаяся вычислительная операция, выполняемая с помощью современных вычислительных средств при решении задач управления движением роботов-манипуляторов, навигации, стабилизации и т. д. Именно вычисление элементарных функций занимает значительную долю времени решения практической задачи на компьютере. В связи с этим важное значение приобретает разработка максимально быстродействующих алгоритмов вычисления элементарных функций для их программной и аппаратной реализации.

Ключевые слова: элементарные функции, вычислительные алгоритмы, программная реализация, быстродействие, управление роботами

ALGORITHMS FOR CALCULATING FUNCTIONS WITH A SINGLE VARIABLE FOR PROCESSING ENCRYPTED NUMBERS IN DISTRIBUTED ENVIRONMENTS

Lapina Maria A., North-Caucasus Federal University, 1 Pushkin St., Stavropol, 355017, Russian Federation,

Cand. Sci. (Physics and Mathematics), e-mail: mlapina@ncfu

Krivozapova Olga V., North-Caucasus Federal University, 1 Pushkin St., Stavropol, 355017, Russian Federation,

postgraduate student, e-mail: obabchenko@ncfu.ru

Hamidov Mukhammadjon R., North Caucasus Federal University, 1 Pushkin St., Stavropol, 355017, Russian Federation,

postgraduate student, e-mail: hamidovmuhammad36@gmail.com

Besaeva Zarina V., South Ossetian State University named after A. A. Tibilova, 8 Putin St. (former Moskovskaya), Tskhinval, 100001, Republic of South Ossetia,

Applicant for a Candidate of Science degree

In the process of solving many practical problems, it is necessary to investigate functional dependencies between quantities that are approximately or exactly expressed using elementary functions. Calculating the values of elementary functions is the most common computational operation performed using modern computing tools in solving problems related to robot manipulator motion control, navigation, stabilization, etc. Calculating elementary functions takes up a significant portion of the time required to solve a practical problem on a computer. Therefore, it is important to develop fast algorithms for calculating elementary functions for their software and hardware implementation.

Keywords: elementary functions, computational algorithms, software implementation, speed, robot control

ВВЕДЕНИЕ

Современная теория приближения функций возникла на основе работ П. Л. Чебышева, который ввел в науку важное понятие наилучшего приближения, в частности равномерного наилучшего приближения, систематически применял его в приложениях и разработал его теоретические основы. Идеи П. Л. Чебышева получили дальнейшее развитие в трудах его учеников Е. И. Золотарева, А. Н. Коркина и братьев А. А. и В. А. Марковых.

На дальнейшее развитие теории приближения функций оказало влияние важное открытие, сделанное в XIX в. немецким математиком Карлом Вейерштрассом: принципиальная возможность приближения произвольной непрерывной функции с любой заданной степенью точности алгебраическим многочленом. Это обусловило то обстоятельство, что алгебраические многочлены стали универсальным средством приближения функций. В практических вычислениях большое распространение получили интерполяционные методы приближения функций.

Как известно, основными методами для вычисления элементарных функций на компьютере являются степенные разложения, многочленные и рациональные приближения, разложения в цепные дроби, итеративные процессы. Широко используется также кусочно-многочленная и кусочно-рациональная аппроксимация.

Четкое определение сходимости ряда, основанное на понятии предела последовательности частичных сумм, появилось лишь в конце XIX в. Положительный ряд всегда имеет сумму. Если эта сумма конечна, то ряд будет сходящимся; а если бесконечна, то ряд – расходящийся.

Вопросы сходимости числовых рядов исследовались многими математиками [1, 6]. В результате исследований было сформулировано достаточно много критериев и признаков для анализа сходимости рядов. Наиболее общим является критерий Коши сходимости числового ряда. На основе этого критерия были доказаны признаки сходимости рядов, они преимущественно и используются для проверки сходимости рядов Тейлора и Маклорена.

Под ускорением сходимости понимается преобразование $\{s_n\}_{n=0}^{\infty} \rightarrow \{s'_k\}_{k=0}^{\infty}$, такое, что s'_k сходятся туда же и быстрее. Как правило, s'_k зависит от первых k элементов s_n . Такое преобразование может применяться итеративно [13]. Для рядов ускорение сходимости – это ускорение сходимости частичных сумм.

Наиболее традиционными способами ускорения сходимости рядов являются следующие приемы повышения точности: использование свойств самоподобия функций, а также представление функций с разбиением области их определения на участки [14].

Дробно-рациональные приближения могут успешно заменять элементарную функцию в тех областях изменения аргумента, где разложение этой функции в степенной ряд расходится и где, следовательно, приближение в виде многочленов в большинстве случаев неприменимы. Существуют методы, позволяющие получать сколь угодно много дробно-рациональных приближений данной функции. Наиболее распространенным из таких методов является метод цепных дробей. В настоящее время интерес к теории цепных дробей объясняется еще и тем, что процесс их вычислений является циклическим, что достаточно легко может быть реализовано на современном языке программирования.

Так как теория цепных дробей обладает рядом замечательных свойств по сравнению с теорией степенных рядов, то целесообразно конструировать на основе теории цепных дробей эффективные численные методы, предназначенные для приближения элементарных функций.

Вычисление прямых тригонометрических функций на компьютере основано на использовании цепной дроби, которая получается при разложении функции $\operatorname{tg}(x)$. Остальные функции ($\sin(x)$, $\cos(x)$ и др.) выражаются согласно известным тригонометрическим формулам. При небольшом количестве итераций (порядка 15) достигается точность вплоть до 18-го знака мантиссы при условии, что значение аргумента по модулю не превышает π .

Основоположителем теории цепных дробей является Леонард Эйлер. Дальнейшие крупные результаты в этой области получены Ж. Л. Лагранжем, П. Л. Чебышевым, А. А. Марковым, О. Перроном, Г. И. Стилтьесом, А. Я. Хинчиным [8, 10]. Значительное развитие теория цепных дробей получила в работах Н. И. Гаврилова, А. Н. Хованского и других математиков. В.Я. Скоробогатко и его ученики ввели в математический оборот ветвящиеся цепные дроби, которые являются естественным обобщением обыкновенных цепных дробей [8]. Аппроксимационные и интерполяционные цепные дроби качественнее описывают приближаемые функции вблизи тех точек, в которые функции обращаются в бесконечность [13].

Многие исследователи отмечают, что свойство цепных дробей мало накапливать погрешность с ростом числа звеньев цепной дроби имеет огромное значение для вычислительной математики [3]. Применение цепной дроби для расчета тригонометрических функций оправдано ввиду ее быстрой сходимости по сравнению с рядом Тейлора. Таким образом, проблема построения эффективных численных методов для приближения элементарных функций является актуальной.

Рядом в математике называется выражение вида $a_1+a_2+a_3+\dots$, составленное из чисел, пронумерованных в определенном порядке, которые называются членами ряда. Таким образом, ряд есть бесконечная сумма.

Рассмотрим задачу разложения функции в ряд, например, в степенной, которая решается в теории функциональных рядов: по заданной функции найти сходящийся функциональный ряд того или иного типа, сумма которого в области сходимости равнялась бы заданной функции. Пусть функция

$y = f(x)$ определена в некоторой окрестности точки x_0 : $U_\delta(x_0) = (x_0 - \delta, x_0 + \delta)$, где $\delta > 0$, причем в этой окрестности функция имеет все производные до $(n + 1)$ порядка. Подберем многочлен n -й степени $P_n(x) = c_0 + c_1(x - x_0) + c_2(x - x_0)^2 + \dots + c_n(x - x_0)^n$ по степеням $(x - x_0)$ так, чтобы в точке x_0 совпадали значения $P_n(x)$ и $f(x)$, а также значения их производных до $(n + 1)$ -го порядка включительно. Тогда говорят, что в окрестности точки x_0 такой многочлен $P_n(x)$ будет приближать данную функцию с некоторой точностью. Коэффициенты многочлена $c_0, c_1, c_2, \dots, c_n$ являются неопределенными коэффициентами, которые необходимо найти, исходя из определенных условий:

$$f(x_0) = P_n(x_0), f'(x_0) = P'_n(x_0), f''(x_0) = P''_n(x_0), \dots, f^{(n)}(x_0) = P_n^{(n)}(x_0).$$

Для нахождения этих коэффициентов найдем производные до n -го порядка от $P_n(x)$:

$$P'_n(x) = c_1 + 2c_2(x - x_0) + 3c_3(x - x_0)^2 + \dots + nc_n(x - x_0)^{n-1},$$

$$P''_n(x) = 2c_2 + 3 \cdot 2 \cdot c_3(x - x_0) + \dots + n(n-1)c_n(x - x_0)^{n-2},$$

...

$$P_n^{(n)}(x) = n(n-1)(n-2)\dots 3 \cdot 2 \cdot 1 \cdot c_n = c_n \cdot n!,$$

$$P_n^{(n+1)}(x) = 0, \text{ при всех } x \in \mathbf{R}.$$

Подставим в эти соотношения $x = x_0$ и приравняем $f^{(k)}(x_0) = P_n^{(k)}(x_0)$, где $k = 0, 1, 2, 3, \dots, n$:

$$f(x_0) = P_n(x_0) = c_0, \quad f'(x_0) = P'_n(x_0) = c_1, \quad f''(x_0) = P''_n(x_0) = 2c_2, \quad f'''(x_0) = P_n'''(x_0) = 2 \cdot 3 \cdot c_3, \quad \dots$$

$f^{(n)}(x_0) = P_n^{(n)}(x_0) = c_n \cdot n!$. Находим выражения для $c_0, c_1, c_2, \dots, c_n$, решая получившуюся систему уравнений:

$$c_0 = f(x_0); \quad c_1 = f'(x_0); \quad c_2 = \frac{f''(x_0)}{2}; \quad c_3 = \frac{f'''(x_0)}{2 \cdot 3} = \frac{f'''(x_0)}{3!}; \quad \dots; \quad c_n = \frac{f^{(n)}(x_0)}{n!}.$$

Получаем общую формулу для определения коэффициентов многочлена c_k : $c_k = \frac{f^{(k)}(x_0)}{k!}$

(*), где $k = 0, 1, 2, 3, \dots, n$.

Тогда многочлен примет следующий вид:

$$P_n(x) = f(x_0) + f'(x_0)(x - x_0) + \dots + \frac{f^{(n)}(x_0)}{n!}(x - x_0)^n = \sum_{k=0}^n \frac{f^{(k)}(x_0)}{k!}(x - x_0)^k.$$

Этот многочлен называется многочленом Тейлора для функции $f(x)$ по степеням $(x - x_0)$,

где $c_k = \frac{f^{(k)}(x_0)}{k!}$ называются коэффициентами многочлена Тейлора, $k = \overline{0, n}$.

Таким образом, для каждой функции $f(x)$, удовлетворяющей поставленным условиям при $x \in U_\delta(x_0)$, можно найти многочлен Тейлора $P_n(x)$. В точке x_0 функция и многочлен совпадают вместе со своими производными до n -го порядка.

Разность $f(x) - P_n(x)$, обозначенную через $R_n(x)$, называют остаточным членом формулы Тейлора, которая имеет следующий вид

$$f(x) = P_n(x) + R_n(x) = \sum_{k=0}^n \frac{f^{(k)}(x_0)}{k!}(x - x_0)^k + R_n(x).$$

Эта формула называется формулой Тейлора для функции $f(x)$ по степеням $(x - x_0)$ порядка n . Отметим, что $R_n(x_0) = R'_n(x_0) = R''_n(x_0) = \dots = R_n^{(n)}(x_0) = 0$.

Величина остаточного члена формулы Тейлора $R_n(x)$ играет важную роль в оценке точности приближения заданной функции многочленом Тейлора. Существует несколько видов остаточных членов.

Остаточный член в форме Пеано

Преобразуем остаточный член формулы Тейлора, используя некоторые понятия из теории пределов [14]:

а) функция $\alpha(x)$ называется бесконечно малой при $x \rightarrow x_0$, если $\lim_{x \rightarrow x_0} \alpha(x) = 0$;

б) бесконечно малая функция $\beta(x)$ называется бесконечно малой более высокого порядка малости относительно бесконечно малой функции $\alpha(x)$ при $x \rightarrow x_0$, если существует

$\lim_{x \rightarrow x_0} \frac{\beta(x)}{\alpha(x)} = 0$ и записывается следующим образом: $\beta = o(\alpha)$ (что читается так: « β есть о малое от α »).

Рассмотрим формулу Тейлора для функции $f(x)$ по степеням $(x - x_0)$ порядка n :

$f(x) = P_n(x) + R_n(x) = \sum_{k=0}^n \frac{f^{(k)}(x_0)}{k!} (x - x_0)^k + R_n(x)$. Остаточный член в этой формуле имеет вид:

$R_n(x) = f(x) - P_n(x)$. Из построения многочлена Тейлора следует

$$R_n(x_0) = R'_n(x_0) = R''_n(x_0) = \dots = R_n^{(n)}(x_0) = 0.$$

Тогда $\lim_{x \rightarrow x_0} \frac{R_n(x)}{(x - x_0)^n} = \lim_{x \rightarrow x_0} \frac{R'_n(x)}{n \cdot (x - x_0)^{n-1}} = \dots = \lim_{x \rightarrow x_0} \frac{R_n^{(n-1)}(x)}{n! \cdot (x - x_0)} = \lim_{x \rightarrow x_0} \frac{R_n^{(n)}(x)}{n!} = 0$, откуда остаточ-

ный член можно записать в виде: $R_n(x) = o((x - x_0)^n)$, т. е. величина остаточного члена есть бесконечно малая более высокого порядка малости относительно $(x - x_0)^n$ при $x \rightarrow x_0$.

Формула Тейлора $f(x) = P_n(x) + R_n(x)$, в которой $R_n(x) = o((x - x_0)^n)$, называется формулой Тейлора с остаточным членом в форме Пеано. Поскольку остаточный член при $x \rightarrow x_0$ является бесконечно малой величиной, то можно считать, что разность $f(x) - P_n(x)$ бесконечно мала, т. е. $f(x) \rightarrow P_n(x)$.

Запишем остаточный член в виде $R_n(x) = \frac{(x - x_0)^{n+1}}{(n+1)!} Q(x)$, где $Q(x)$ есть некоторая функция, под-

лежащая определению. Можно доказать, что $Q(x) = f^{(n+1)}(\xi)$, где точка ξ заключена между x и x_0 :

$\xi = x_0 + \theta(x - x_0)$, $0 < \theta < 1$, т. е. остаточный член имеет вид: $R_n(x) = \frac{(x - x_0)^{n+1}}{(n+1)!} f^{(n+1)}(\xi)$. Тогда фор-

мула Тейлора примет вид: $f(x) = P_n(x) + R_n(x) = \sum_{k=0}^n \frac{f^{(k)}(x_0)}{k!} (x - x_0)^k + \frac{(x - x_0)^{n+1}}{(n+1)!} f^{(n+1)}(\xi)$, который

называется формулой Тейлора с остаточным членом в форме Лагранжа.

Если в формуле Тейлора с остаточным членом в форме Лагранжа положить $n = 0$, то получаем формулу конечного приращения: $f(x) = f(x_0) + (x - x_0)f'(\xi)$ (теорема Лагранжа).

Если в формуле Тейлора положить $x_0 = 0$, то получим формулу [13] Маклорена:

$f(x) = f(0) + \frac{f'(0)}{1!} \cdot x + \frac{f''(0)}{2!} \cdot x^2 + \dots + \frac{f^{(n)}(0)}{n!} \cdot x^n + R_n(x)$, где остаточный член можно записать

в форме Пеано: $R_n(x) = o(x^n)$ или в форме Лагранжа: $R_n(x) = \frac{f^{(n+1)}(\theta x)}{(n+1)!} x^{n+1}$.

Заметим, так как расчет погрешности трудоемкая операция, то на практике для обеспечения заданной точности все промежуточные вычисления проводят с одним или двумя запасными знаками.

Пусть функция $y = f(x)$ определена в некоторой окрестности точки x_0 : $U_R(x_0) = (x_0 - R, x_0 + R)$, $R > 0$ и имеет производные любого порядка, тогда для этой функции формально

можно составить ряд по степеням $(x - x_0)$: $f(x) \sim c_0 + c_1(x - x_0) + \dots + c_n(x - x_0)^n + \dots = \sum_{k=0}^{\infty} c_k(x - x_0)^k$, где

$$c_k = \frac{f^{(k)}(x_0)}{k!}.$$

Обобщенный степенной ряд вида $\sum_{k=0}^{\infty} \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k$ называется рядом Тейлора для функции $f(x)$ по степеням $(x-x_0)$. Если положить $x_0=0$, то получим ряд $\sum_{k=0}^{\infty} \frac{f^{(k)}(0)}{k!} \cdot x^k$, который носит название ряда Маклорена для функции $f(x)$ по степеням x [4, 8].

Задача. Пусть задана функция $f(x)$, бесконечно дифференцируемая в окрестности точки x_0 : (x_0-R, x_0+R) , и пусть для этой функции составлен ряд Тейлора по степеням $(x-x_0)$: $\sum_{k=0}^{\infty} \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k$ и его сумма равна $S(x)$. Если интервал (x_0-R, x_0+R) , $R>0$, является интервалом сходимости данного ряда с радиусом сходимости R , то можно записать равенство: $S(x) = \sum_{k=0}^{\infty} \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k$ при всех $x \in (x_0-R, x_0+R)$.

Поскольку существуют функции, для которых сумма ряда Тейлора не совпадает с данной функцией, интересно выяснить, при каких условиях такой степенной ряд имеет своей суммой функцию $f(x)$, т. е. когда $f(x) = S(x)$.

Пусть ряд Тейлора $\sum_{k=0}^{\infty} \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k$ имеет интервал сходимости (x_0-R, x_0+R) , где R – радиус сходимости. Тогда, если $S_n(x) = \sum_{k=0}^n \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k$ – частичная сумма этого ряда, то $\forall x \in (x_0-R, x_0+R)$ существует $\lim_{n \rightarrow \infty} S_n(x) = S(x)$. Рассмотрим теорему, которая дает условия того, что $f(x) = S(x)$.

Условия сходимости ряда Тейлора к исходной функции

Теорема 2 (необходимый и достаточный признак сходимости ряда Тейлора к функции $f(x)$). Для того чтобы ряд Тейлора $\sum_{k=0}^{\infty} \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k = S(x)$, $\forall x \in U_R(x_0) = (x_0-R, x_0+R)$, имел своей суммой функцию $f(x)$, т. е. $S(x) = f(x)$, необходимо и достаточно, чтобы для всех $x \in U_R(x_0)$ существовал предел $\lim_{n \rightarrow \infty} R_n(x) = 0$, где $R_n(x)$ – остаток ряда Тейлора.

Доказательство.

1) Необходимость. Пусть функция $f(x)$ есть сумма ряда Тейлора на указанном промежутке:

$f(x) = \sum_{k=0}^{\infty} \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k$, или $f(x) = S_n(x) + R_n(x)$, где $S_n(x)$ – частичная сумма ряда Тейлора, $R_n(x)$ – остаток ряда. Тогда при всех $x \in U_R(x_0) = (x_0-R, x_0+R)$ существует предел $\lim_{n \rightarrow \infty} S_n(x) = S(x)$, и так как $S(x) = f(x)$, то существует предел $\lim_{n \rightarrow \infty} R_n(x) = \lim_{n \rightarrow \infty} (f(x) - S_n(x)) = f(x) - \lim_{n \rightarrow \infty} S_n(x) = f(x) - S(x) = 0$, т. е. $R_n(x) \rightarrow 0 \forall x \in U_R(x_0)$.

Необходимость доказана.

2) Достаточность. Пусть существует $\lim_{n \rightarrow \infty} R_n(x) = 0$; так как функция $f(x)$ бесконечно дифференцируема при всех $x \in U_R(x_0)$, то для нее имеет место формула Тейлора:

$f(x) = \sum_{k=0}^n \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k + R_n(x)$, $\forall x \in (x_0-R, x_0+R)$, где $R_n(x)$ – остаточный член формулы Тейлора, который совпадает с остатком ряда. Тогда частичная сумма соответствующего ряда Тейлора имеет вид: $S_n(x) = \sum_{k=0}^n \frac{f^{(k)}(x_0)}{k!} (x-x_0)^k = f(x) - R_n(x)$. Рассмотрим предел $S_n(x)$, который обозначим через $S(x)$, учитывая, что $\lim_{n \rightarrow \infty} R_n(x) = 0$: $S(x) = \lim_{n \rightarrow \infty} S_n(x) = \lim_{n \rightarrow \infty} (f(x) - R_n(x)) = f(x)$, т. е. $S(x) = f(x)$. Достаточность доказана.

Замечание. Если $\lim_{n \rightarrow \infty} R_n(x) \neq 0$, то сумма ряда Тейлора может не совпадать с данной функцией ($S(x) \neq f(x)$), хотя сам ряд может сходиться к другой функции.

Необходимое и достаточное условие сходимости ряда Тейлора к исходной функции не удобно для проверки на практике конкретных рядов; существуют достаточные условия разложения функции $f(x)$ в ряды Тейлора – Маклорена.

Лемма. Для любого $x \in \mathbb{R}$ существует следующий предел: $\lim_{n \rightarrow \infty} \frac{x^n}{n!} = 0$.

Доказательство. Рассмотрим степенной ряд $\sum_{n=0}^{\infty} \frac{x^n}{n!} = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots + \frac{x^n}{n!} + \dots$, общий член которого $u_n(x) = \frac{x^n}{n!}$. Найдем радиус и область сходимости этого ряда, используя признак Даламбера:

$u_{n+1}(x) = \frac{x^{n+1}}{(n+1)!}$; вычисляем предел $\lim_{n \rightarrow \infty} \left| \frac{u_{n+1}(x)}{u_n(x)} \right| = \lim_{n \rightarrow \infty} \left| \frac{x^{n+1} \cdot n!}{(n+1) \cdot x^n} \right| = \lim_{n \rightarrow \infty} \left(\frac{|x|}{n+1} \right) = 0$, т. е. радиус сходимости ряда $R = \infty$. Следовательно, рассмотренный ряд сходится для всех $x \in \mathbb{R}$. Тогда по необходимому признаку сходимости общий член ряда $u_n(x) = \frac{x^n}{n!} \rightarrow 0$, $n \rightarrow \infty$, т. е. $\lim_{n \rightarrow \infty} \frac{x^n}{n!} = 0$ для любого $x \in \mathbb{R}$.

Теорема 3. Пусть функция $f(x)$ определена и бесконечно дифференцируема на интервале $(-a; a)$, $a > 0$. Если производные любого порядка ограничены одним и тем же числом, т. е. существует такое число $M > 0$, что для каждого натурального $n \in \mathbb{N}$ и всех $x \in (-a; a)$ выполняется

неравенство: $\left| f^{(n)}(x) \right| \leq M$, тогда остаток ряда Маклорена $R_n(x) = \sum_{k=n+1}^{\infty} \frac{f^{(k)}(0) \cdot x^k}{k!} \rightarrow 0$ при $n \rightarrow \infty$,

а значит, $f(x) = S(x) = \sum_{k=0}^{\infty} \frac{f^{(k)}(0)}{k!} \cdot x^k \quad \forall x \in (-a, a)$.

Доказательство. Покажем, что остаток ряда Маклорена стремится к нулю при $n \rightarrow \infty$. Запишем для функции $f(x)$ формулу Маклорена с остаточным членом в форме Лагранжа:

$f(x) = \sum_{k=0}^n \frac{f^{(k)}(0)}{k!} \cdot x^k + R_n(x)$, где $\sum_{k=0}^n \frac{f^{(k)}(0)}{k!} \cdot x^k = P_n(x)$ – многочлен Маклорена,

а $R_n(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!} \cdot x^{n+1}$. Отметим, что частичная сумма ряда Маклорена $S_n(x)$ является этим многочленом $P_n(x)$, а остаток ряда есть $R_n(x)$. Выполним его оценку, используя условия

данной теоремы и учитывая, что $\left| f^{(n)}(x) \right| \leq M$ для всех $x \in (-a; a)$:

$\left| R_n(x) \right| = \left| \frac{f^{(n+1)}(\xi) \cdot x^{n+1}}{(n+1)!} \right| = \frac{|x|^{n+1}}{(n+1)!} \left| f^{(n+1)}(\xi) \right| \leq \frac{|x|^{n+1}}{(n+1)!} \cdot M$. По лемме $\frac{|x|^{n+1}}{(n+1)!} \rightarrow 0$ при $n \rightarrow \infty$, тогда

$\lim_{n \rightarrow \infty} R_n(x) = 0$, $\forall x \in (-a; a)$. Следовательно, по теореме 1 о необходимом и достаточном при-

знаке сходимости ряда Тейлора – Маклорена к исходной функции получаем $f(x) = \sum_{k=0}^{\infty} \frac{f^{(k)}(0)}{k!} \cdot x^k$.

Теорема доказана.

Используем изложенную выше теорию для разложения некоторых элементарных функций в степенные ряды.

Разложение в степенной ряд функции $f(x) = \frac{1}{1-x}$ имеет вид:

$$\frac{1}{1-x} = 1 + x + x^2 + \dots = \sum_{n=0}^{\infty} x^n, \quad x \in (-1; 1). \quad (1)$$

Рассмотрим ряд геометрической прогрессии $1+x+x^2+x^3+\dots+x^n+\dots$, знаменатель которой $q=x$ и $b_1=1$. Можно показать, что интервал сходимости этого ряда $(-1;1)$, $R=1$ и сумма этого ряда $S(x)=\frac{1}{1-x}$ (сумма ряда бесконечно убывающей геометрической прогрессии вычисляется по формуле $S(x)=\frac{b_1}{1-q}$).

Оценим остаток ряда: $R_n(x)=x^{n+1}+x^{n+2}+\dots=x^{n+1}(1+x+x^2+\dots)=\frac{x^{n+1}}{1-x}$; при $x \in (-1;1)$ $R_n(x) \rightarrow 0$ при $n \rightarrow \infty$, тогда на основании теоремы 1 рассмотренный ряд имеет своей суммой функцию $f(x)=\frac{1}{1-x}$. Разложение (1) имеет место.

Приведем пример вычислений в системе компьютерной алгебры из класса систем автоматизированного проектирования MathCad (рис. 1).

$$P := 4 * a \tan(1) \quad h := \frac{P}{40} \quad p(x) := x + \frac{x^3}{3} \quad d(x) := \frac{x}{1 - \frac{x^2}{3}} \quad i := 0, 1..10 \quad x_i := i \cdot h$$

$$p_i := p(x_i) \quad d_i := d(x_i) \quad y_i := \operatorname{tg}(x_i) \quad rp_i := |y_i - p_i| \quad rd_i := |y_i - d_i|$$

Рисунок 1 – Программа вычислений в среде MathCad

Здесь $p_i, d_i, y_i, rp_i, rd_i$ ($i := 0,1,\dots,10$) – сеточные функции на сетке ω_h , а именно: p_i – таблица значений полинома (*), d_i – таблица значений подходящей дроби (**), y_i – таблица точных значений функции $\operatorname{tg} x$, rp_i – таблица значений $|y_i - p_i|$, rd_i – таблица значений $|y_i - d_i|$. Результаты вычислений представлены в таблицах 1, 2.

Таблица 1 – Результаты вычисления погрешности приближения функции $y = \operatorname{tg} x$ тейлоровскими многочленами p_3 на сетке узлов ω_h

I	x_i	p_i	y_i	$ rp_i $
0	0	0	0	0
1	0,07854	0,078701	0,078702	$3,994605 * 10^{-7}$
2	0,15708	0,158372	0,158384	$1,287945 * 10^{-5}$
3	0,235619	0,23998	0,240079	$9,90524 * 10^{-5}$
4	0,314159	0,324495	0,32492	$4,250053 * 10^{-4}$
5	0,392699	0,412885	0,414214	$1,328103 * 10^{-3}$
6	0,471239	0,506121	0,509525	$3,40449 * 10^{-3}$
7	0,549779	0,60517	0,612801	$7,630652 * 10^{-3}$
8	0,628319	0,711002	0,726543	0,015541
9	0,706858	0,0824585	0,854081	0,029495
10	0,785398	0,946889	1	0,053111

Таблица 2 – Результаты вычисления погрешности приближения функции $y = \operatorname{tg} x$ подходящей дробью цепной дроби d_2 на сетке узлов ω_h

I	x_i	d_i	y_i	rd_i
0	0	0	0	0
1	0,07854	0,078702	0,078702	$6,672373 * 10^{-8}$
2	0,15708	0,158382	0,158384	$2,165649 * 10^{-6}$
3	0,235619	0,240062	0,240079	$1,684228 * 10^{-5}$
4	0,314159	0,324846	0,32492	$7,341664 * 10^{-5}$
5	0,392699	0,413979	0,414214	$2,342074 * 10^{-4}$
6	0,471239	0,508909	0,509525	$6,160425 * 10^{-4}$
7	0,549779	0,611376	0,612801	$1,424567 * 10^{-3}$
8	0,628319	0,723531	0,726543	$3,011074 * 10^{-3}$
9	0,706858	0,0848111	0,854081	$5,969838 * 10^{-3}$
10	0,785398	0,988689	1	0,011311

Опустим промежуточные вычисления, приведенные нами для следующих приближений в работе [13, 14] (рис. 2).

$$p5(x) = x + \frac{1}{3}x^3 + \frac{2}{15}x^5,$$

$$d3(x) = \frac{x}{1} \frac{x^2}{3} \frac{x^2}{5}$$

$$p7(x) = x + \frac{1}{3}x^3 + \frac{2}{15}x^5 + \frac{17}{315}x^7,$$

$$d4(x) = \frac{x}{1} \frac{x^2}{3} \frac{x^2}{5} \frac{x^2}{7}$$

$$p9(x) = x + \frac{1}{3}x^3 + \frac{2}{15}x^5 + \frac{17}{315}x^7 + \frac{62}{2835}x^9,$$

$$d5(x) = \frac{x}{1} \frac{x^2}{3} \frac{x^2}{5} \frac{x^2}{7} \frac{x^2}{9}$$

$$p11(x) = x + \frac{1}{3}x^3 + \frac{2}{15}x^5 + \frac{17}{315}x^7 + \frac{62}{2835}x^9 + \frac{1382}{155925}x^{11},$$

$$d6(x) = \frac{x}{1} \frac{x^2}{3} \frac{x^2}{5} \frac{x^2}{7} \frac{x^2}{9} \frac{x^2}{11}$$

$$p13(x) = x + \frac{1}{3}x^3 + \frac{2}{15}x^5 + \frac{17}{315}x^7 + \frac{62}{2835}x^9 + \frac{1382}{155925}x^{11} + \frac{21844}{6081075}x^{13},$$

$$d7(x) = \frac{x}{1} \frac{x^2}{3} \frac{x^2}{5} \frac{x^2}{7} \frac{x^2}{9} \frac{x^2}{11} \frac{x^2}{13}$$

$$p15(x) = x + \frac{1}{3}x^3 + \frac{2}{15}x^5 + \frac{17}{315}x^7 + \frac{62}{2835}x^9 + \frac{1382}{155925}x^{11} + \frac{21844}{6081075}x^{13} + \frac{929569}{638512875}x^{15},$$

$$d8(x) = \frac{x}{1} \frac{x^2}{3} \frac{x^2}{5} \frac{x^2}{7} \frac{x^2}{9} \frac{x^2}{11} \frac{x^2}{13} \frac{x^2}{15}.$$

Рисунок 2 – Результаты вычислений

Для приближения функции $y = \operatorname{tg}(x)$ на сетке узлов ω_h используем полином наилучшего приближения [13, 14] (рис. 3).

$$\operatorname{tg} x \approx PN13(x) = \sum_{k=0}^6 a_{2k+1} x^{2k+1},$$

Рисунок 3 – Результаты вычислений

Значения коэффициентов при вычислении $y = \operatorname{tg}(x)$ полиномами наилучшего приближения PN1 показаны в таблице 3.

Таблица 3 – Значения коэффициентов при вычислении $y = \operatorname{tg}(x)$ полиномами наилучшего приближения PN13

A ₁	1,00000002	A ₉	0,02457096
A ₃	0,33333082	A ₁₁	0,00294045
A ₅	0,13339762	A ₁₃	0,00947324
A ₇	0,0593536		

Результаты вычисления погрешности приближения функций показаны на рисунках 4–5.

i	x_i	P_i	y_i	$ rP_i $
0	0	0	0	0
1	0.078539816339745	0.078701706824618	0.078701706824618	0
2	0.15707963267949	0.158384440324535	0.158384440324536	$1.25 \cdot 10^{-15}$
3	0.235619449019234	0.240078759079546	0.240078759080116	$5.71 \cdot 10^{-13}$
4	0.314159265358979	0.324919696189446	0.324919696232906	$4.35 \cdot 10^{-11}$
5	0.392699081698724	0.414213561108245	0.414213562373095	$1.27 \cdot 10^{-9}$
6	0.471238898038469	0.509525429417949	0.509525449494429	$2.01 \cdot 10^{-8}$
7	0.549778714378214	0.612800577915268	0.612800788139932	$2.11 \cdot 10^{-7}$
8	0.628318530717959	0.726540900468958	0.726542528005361	$1.63 \cdot 10^{-6}$
9	0.706858347057703	0.854070653934264	0.854080685463467	$1.01 \cdot 10^{-5}$
10	0.785398163397448	0.999948191749367	1	$5.19 \cdot 10^{-5}$

Рисунок 4 – Результаты вычисления погрешности приближения функции $y = \operatorname{tg}(x)$ тейлоровскими многочленами p_{13} на сетке узлов ω_h

i	x_i	d_i	y_i	rd_i
0	0	0	0	0
1	0.078539816339745	0.078701706824618	0.078701706824618	0
2	0.15707963267949	0.158384440324536	0.158384440324536	0
3	0.235619449019234	0.240078759080116	0.240078759080116	0
4	0.314159265358979	0.324919696232906	0.324919696232906	0
5	0.392699081698724	0.414213562373095	0.414213562373095	0
6	0.471238898038469	0.509525449494429	0.509525449494429	0
7	0.549778714378214	0.612800788139931	0.612800788139932	0
8	0.628318530717959	0.726542528005356	0.726542528005361	$5.10 \cdot 10^{-15}$
9	0.706858347057703	0.854080685463433	0.854080685463467	$3.37 \cdot 10^{-14}$
10	0.785398163397448	0.999999999999813	1	$1.87 \cdot 10^{-13}$

Рисунок 5 – Результаты вычисления погрешности приближения функции $y = \operatorname{tg}(x)$ подходящей дробью цепной дроби d_7 на сетке узлов ω_h

Исследование посвящено актуальной проблеме ускорения сходимости многочленных и дробно-рациональных приближений тригонометрических и гиперболических функций.

Основными методами для вычисления функций на компьютере являются: степенные разложения, рациональные приближения, разложения в цепные дроби, итеративные процессы и др. Достаточно распространено и используется кусочно-многочленная и кусочно-рациональная аппроксимация. Различные модели сопоставимы одной той же функции, выбор которых зависит от типа решаемой задачи. Полученные в работе результаты могут быть использованы для программной реализации быстродействующих алгоритмов вычисления элементарных функций при решении естественнонаучных, прикладных задач в различных областях.

Список литературы

1. Апарина, Л. В. Числовые и функциональные ряды / Л. В. Апарина. – Санкт-Петербург : Лань, 2012. – 160 с.
2. Бахвалов, Н. С. Численные методы / Н. С. Бахвалов, Н. П. Жидков, Г. М. Кобельков. – Москва : БИНОМ. Лаборатория знаний, 2012. – 636 с.
3. Боднарчук, П. И. Успехи и задачи теории цепных и ветвящихся цепных дробей / П. И. Боднарчук, В. Я. Скоробогатко // Цепные дроби их применения: сб. научных трудов / под ред. В. Я. Скоробогатко. – Киев : Институт математики АН УССР. 1976. – С. 5–8.
4. Бермант, А. Ф. Краткий курс математического анализа для ВТУЗОВ / А. Ф. Бермант, И. Г. Араманич. – Изд. 5-е. – Москва : Наука, 1967. – 735 с.
5. Бухштаб, А. А. Теория чисел / А. А. Бухштаб. – Изд. 2-е, перераб. и доп. – Москва : Просвещение, 1966. – 384 с.
6. Винер, Н. Интеграл Фурье и некоторые его приложения / Н. Винер. – Москва : Физматгиз, 1983.
7. Власова, Е. А. Ряды / Е. А. Власова ; под ред. В. С. Зарубина, А. П. Крищенко. – Москва : Изд-во МГТУ им. Н.Э. Баумана, 2000. – 673 с.
8. Воробьев, Н. Н. Теория рядов / Н. Н. Воробьев. – Москва : Наука, 1975.

9. Гапоненко, Н. П. Цепные дроби в синтезе устройств частотной селекции на функциональных времязадающихся элементах / Н. П. Гапоненко, Н. Н. Рябец // Цепные дроби их применения : сб. научных трудов / под ред. В. Я. Скоробогатко. Институт математики АН УССР. – Киев, 1976. – С. 48 – 49.
10. Глейзер, Г. И. История математики в средней школе. Пособие для учителей / Г. И. Глейзер. – Москва : Просвещение, 1970. – 461 с.
11. Данилов, В. Л. Математический анализ. Функции, пределы, ряды, цепные дроби / В. Л. Данилов, А. Н. Иванова, Е. К. Исакова и др. – Москва : Физматгиз, 1961. – 440 с.
12. Бейкер, Дж. мл. Аппроксимации Паде. Основы теории. Обобщения и приложения. / Дж. Бейкер мл., П. Грейвс-Моррис ; пер. с англ. Е. А. Рахманова и С. П. Сутина ; под ред. А. А. Гончара. – Москва : Мир, 1986. – 498 с.
13. Демидович, Б. П. Основы вычислительной математики / Б. П. Демидович, И. А. Марон. – Москва : Наука, 1966. – 664 с.
14. Джоунс, В. Трон. Непрерывные дроби. Аналитическая теория и приложения : пер. с англ. / В. Джоунс. – Москва : Мир, 1985. – 414 с.
15. Доморяд, П. А. Численные и графические методы решения уравнений / П. А. Доморяд // Энциклопедия элементарной математики. – Москва ; Ленинград : Гостехиздат, 1951. – Т. 2. – С. 313–417.
16. Ефимов, А. В. Математический анализ (специальные разделы) / А. В. Ефимов. – Москва : Высш. шк., 1980. – Ч. 1.
17. Зотов, Е. Н. Решение обратных задач теплопроводности с помощью цепных дробей / Е. Н. Зотов, Н. П. Пучков, Ю. С. Шаталов // Цепные дроби их применения : сб. научных трудов / под ред. В. Я. Скоробогатко. – Киев : Институт математики АН УССР, 1976. – С. 56–57.

References

1. Aparina, L. V. *Numerical and functional series*. St. Petersburg, Lan, 2012. 160 p. (In Russ.).
2. Bakhvalov, N. S., Zhidkov, N. P., Kobelkov, G. M. *Numerical methods*. Moscow, BINOM. Laboratory of Knowledge, 2012. 636 p. (In Russ.).
3. Bodnarchuk, P. I., Skorobogatko, V. Ya. Successes and tasks of the theory of chain and branching chain fractions. *Chain fractions of their application: collection of scientific papers*. Edited by V. Ya. Skorobogatko. Kiev, Institute of Mathematics of the Academy of Sciences of the Ukrainian SSR, 1976, pp. 5–8 (In Russ.).
4. Bermant, A. F., Aramanovich, I. G. *A short course in mathematical analysis for higher education institutions*. 5th ed. Moscow, Nauka Publ., 1967. 735 p. (In Russ.).
5. Bukhshtab, A. A. *Theory of numbers*. 2nd ed., rev. and add. Moscow, Prosveshchenie Publ., 1966. 384 p. (In Russ.).
6. Viner, N. *The Fourier integral and some of its applications*. Moscow, Fizmatgiz Publ., 1983 (In Russ.).
7. Vlasova, E. A. Series. Edited by V. Szarubin, A. P. Krishchenko. Moscow, Publishing House of Bauman Moscow State Technical University, 2000. 673 p. (In Russ.).
8. Vorobyov, N. N. *Theory of Series*, Moscow, Nauka Publ., 1975 (In Russ.).
9. Gaponenko, N. P., Ryabets, N. N. Chain fractions in the synthesis of frequency selection devices on functional time-decaying elements. *Chain fractions of their application: collection of scientific papers*. Edited by V. Ya. Skorobogatko. Institute of Mathematics of the Academy of Sciences of the Ukrainian SSR. Kiev, 1976, pp. 48–49 (In Russ.).
10. Glaser, G. I. History of mathematics in secondary schools. A manual for teachers. Moscow, Prosveshchenie Publ., 1970. 461 p. (In Russ.).
11. Danilov, V. L., Ivanova, A. N., Isakova, E. K. et al. *Mathematical analysis. Functions, limits, series, continued fractions*. Moscow, Fizmatgiz Publ., 1961. 440 p. (In Russ.).
12. Baker, J. Jr. Graves-Morris, P. Approximations of the Case. Fundamentals of theory. Generalizations and applications. Translated from English by E. A. Rakhmanov and S. P. Suetin, edited by A. A. Gonchar. 1981. Moscow Mir Publ.. 1986. 498 p. (In Russ.).
13. Demidovich, B. P., Maron, I. A. *Fundamentals of Computational Mathematics*. Moscow, Nauka Publ., 1966. 664 p. (In Russ.).
14. Jones, V. *Throne. Continued fractions. Analytical theory and applications*. Translated from English. Moscow, Mir Publ., 1985. 414 p. (In Russ.).
15. Domoryad, P. A. Numerical and graphical methods for solving equations. *Encyclopedia of Elementary Mathematics*. Moscow, Leningrad, Gostekhizdat Publ., 1951, vol. 2, pp. 313–417 (In Russ.).
16. Efimov, A. V. *Mathematical analysis (special sections)*. Moscow, Higher School of Economics, 1980, part 1 (In Russ.).
17. Zotov, E. N., Puchkov N. P., Shatalov Yu. S. Solving inverse problems of thermal conductivity using chain fractions. *Chain fractions of their Applications: collection of scientific papers*. Edited by V. Ya. Skorobogatko. Kiev, Institute of Mathematics of the Academy of Sciences of the Ukrainian SSR, 1976, pp. 56–57 (In Russ.).

Статья поступила в редакцию 11.09.2025; одобрена после рецензирования 18.09.2025; принята к публикации 30.09.2025.

The article was submitted 11.09.2025; approved after reviewing 18.09.2025; accepted for publication 30.09.2025.

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ, ЧИСЛЕННЫЕ МЕТОДЫ И КОМПЛЕКСЫ ПРОГРАММ

УДК 004.942:579.695

МНОГОВАРИАНТНОСТЬ РЕШЕНИЯ ОПТИМИЗАЦИОННОЙ ЗАДАЧИ ПОИСКА ПАРАМЕТРОВ МАТЕМАТИЧЕСКОЙ МОДЕЛИ ПРОЦЕССА БИОРАЗЛОЖЕНИЯ ПАРАЦЕТАМОЛА

Кожухарь Олеся Юрьевна, Российский химико-технологический университет имени Д.И. Менделеева, 125047, Российская Федерация, г. Москва, Миусская площадь, 9, аспирант, AuthorID: 1077181, SPIN code: 5759-6225, ORCID: 0009-0005-9965-3961, e-mail: olesyakozhukhar@yandex.ru

Скичко Алексей Сергеевич, Российский химико-технологический университет имени Д.И. Менделеева, 125047, Российская Федерация, г. Москва, Миусская площадь, 9, кандидат технических наук, доцент, AuthorID: 52434, SPIN-код: 8102-9810, ORCID: 0000-0003-0022-0209, e-mail: olf_1@list.ru

В работе рассматривается проблематика многовариантности решения многомерной оптимизационной задачи на примере оценки параметров модели процесса разложения парацетамола штаммом бактерий *Staphylococcus sciuri* DPP1. Поверхность отклика, полученная в ходе решения оптимизационной задачи, представляет собой многомерную овражную структуру, в связи с чем типовым результатом при использовании классических оптимизационных алгоритмов с возможностью задания разных начальных приближений параметров модели становится не единое решение в виде глобального экстремума критерия оптимизации, а множество альтернативных наборов значений параметров модели, обеспечивающих схожую кинетику процесса. Авторами данной работы проведены обобщения полученных решений на основе корреляционных зависимостей и выработаны критерии оценки влияния случайно найденного решения оптимизационной задачи на прогнозирование кинетических траекторий. Также была дана оценка возможного изменения времени протекания процесса в зависимости от найденного частного решения оптимизационной задачи.

Ключевые слова: биоразложение парацетамола, оптимизация, математическое моделирование, овражная функция, поверхность отклика, корреляционные зависимости параметров модели, многовариантность решений оптимизационной задачи

MULTIVARIABILITY SOLUTION OF OPTIMIZATION PROBLEM OF SEARCHING PARAMETERS OF MATHEMATICAL MODEL OF PARACETAMOL BIODEGRADATION PROCESS

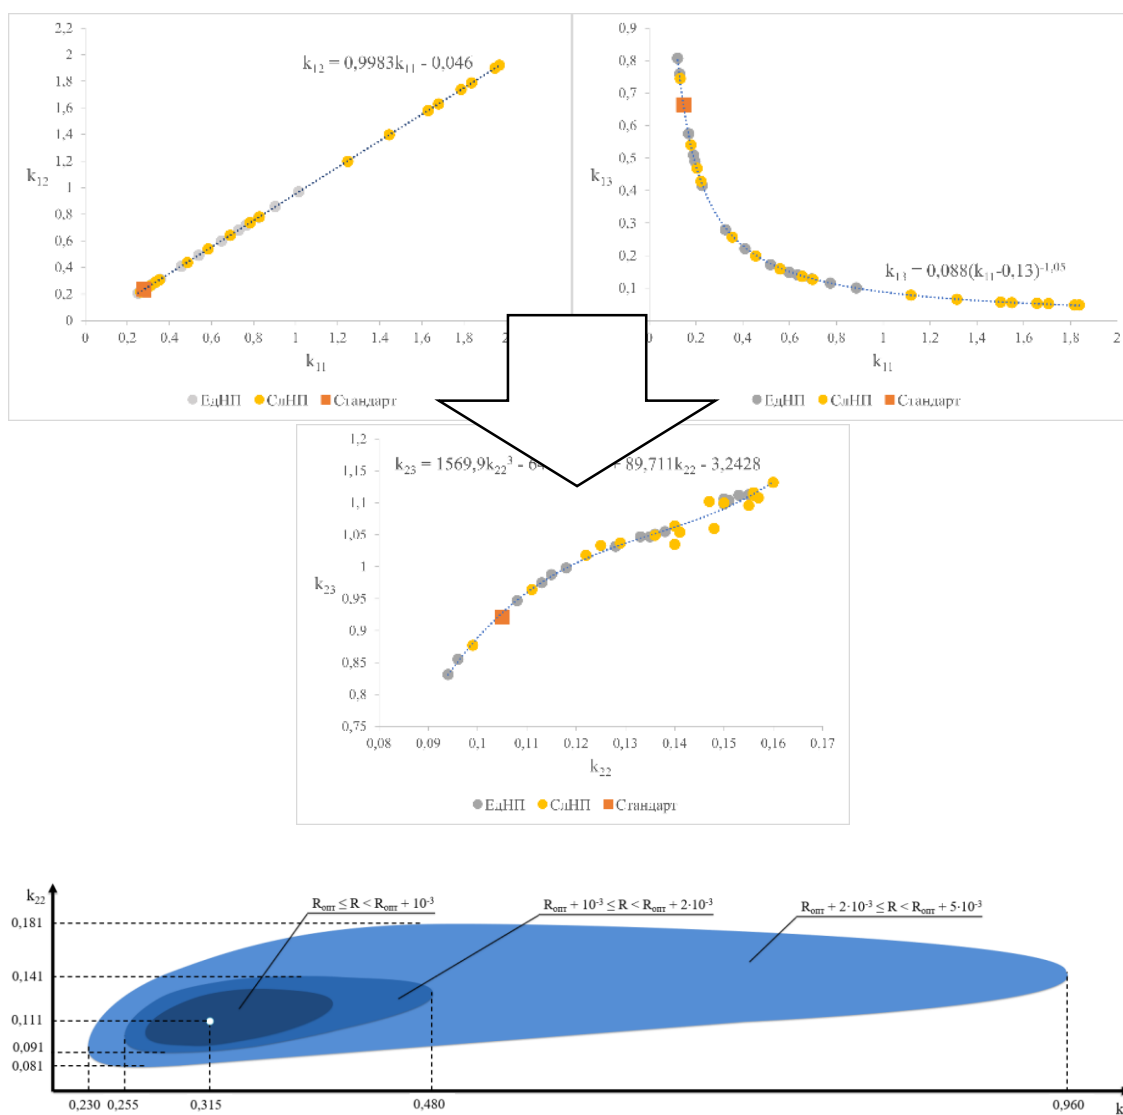
Kozhukhar Olesya Yu., D.I. Mendeleev University of Chemical Technology of Russia, 9 Miusskaya Square, Moscow, 125047, Russian Federation, graduate student, AuthorID: 1077181, SPIN code: 5759-6225, e-mail: olesyakozhukhar@yandex.ru

Skichko Alexey S., D.I. Mendeleev University of Chemical Technology of Russia, 9 Miusskaya Square, Moscow, 125047, Russian Federation, Cand. Sci. (Engineering), Assistant Professor, AuthorID: 52434, SPIN-код: 8102-9810, ORCID: 0000-0003-0022-0209, e-mail: olf_1@list.ru

In this work we consider the problem of multivariate solution of multivariate optimization problem on the example of estimation of parameters of the model of paracetamol decomposition process by *Staphylococcus sciuri* DPP1 bacterial strain. The response surface obtained during the solution of the optimization problem is a multidimensional gully structure, in connection with which the typical result when using classical optimization algorithms with the possibility of setting different initial approximations of the model parameters is not a single solution in the form of a global extremum of the optimization criterion, but a set of alternative sets of values of the model parameters, providing similar kinetics of the process. The authors of this work have generalized the obtained solutions on the basis of correlation dependencies and developed criteria for evaluating the influence of a randomly found solution of the optimization problem on the prediction of kinetic trajectories. They also evaluated the possible change in the time of the process depending on the found private solution of the optimization problem.

Keywords: paracetamol biodegradation, optimization, mathematical modeling, gully function, response surface, correlation dependencies of model parameters, multivariate solutions of optimization problem

Graphical annotation (Графическая аннотация)



ВВЕДЕНИЕ

Математическое моделирование играет ключевую роль в понимании и прогнозировании сложных процессов, в том числе в биоразложении фармацевтических препаратов в окружающей среде. Парацетамол, широко используемый анальгетик и антипиретик, аккумулируется в сточных водах и природных водоемах и оказывает негативное воздействие на экосистемы [1, 2]. Разработка математической модели процесса биоразложения парацетамола позволяет спрогнозировать поведение системы в окружающей среде.

Одной из важнейших задач при построении математической модели является определение ее параметров, наиболее точно отражающих экспериментальные данные. Эта задача часто формулируется как оптимизационная, где целевой функцией выступает мера расхождения между расчетными и экспериментальными измерениями. Однако в процессе работы нередко обнаруживается, что традиционные подходы к нелинейной оптимизации демонстрируют низкую эффективность при решении практических задач. Это проявляется в существенном снижении скорости приближения к решению или даже в полной остановке вычислительного процесса, когда оптимальная точка еще не достигнута [3–6]. При этом во многих случаях оптимизационная задача поиска параметров модели имеет не единственное решение, а множество альтернативных наборов параметров, обеспечивающих сравнимое качество аппроксимации экспериментальных данных [7]. Такая многовариантность решения оптимизационных задач, как правило, связана с наличием овражных многомерных функций в пространстве искомых параметров модели, природа которых может быть связана с нелинейностью моделей биоразложения, отсутствием возможности достаточно точных измерений, ограниченным объемом экспериментальной информации, а также общей сложностью биосистем.

Многовариантность решения оптимизационной задачи поиска параметров модели биоразложения парацетамола представляет собой важную проблему, требующую тщательного анализа. С одной стороны, она указывает на существующую неопределенность в идентификации параметров модели и может привести к различным интерпретациям результатов моделирования изучаемого процесса. С другой стороны, анализ множества альтернативных решений позволяет выявить наиболее устойчивые параметры модели и оценить чувствительность предсказаний по модели к вариациям ее параметров.

В данной работе исследуется многовариантность решения оптимизационной задачи поиска параметров математической модели на примере процесса биоразложения парацетамола штаммом бактерий *Staphylococcus sciuri* DPP1. Микроорганизмы рода *Staphylococcus* способны разрушать парацетамол, используя входящий в него углерод в качестве единственного источника углерода и энергии. Экспериментальные измерения изменения концентрации парацетамола при разных условиях описаны в [8]. В [9] представлен анализ экспериментальных данных, обоснованы положения математической модели процесса, описаны используемые уравнения и найдено частное решение оптимизационной задачи идентификации параметров модели. Однако, как показали дальнейшие исследования, это решение оказалось далеко не единственным. Таким образом, следующим этапом в данном исследовании стала необходимость систематизации возможных альтернативных решений поставленной оптимизационной задачи.

ПОСТАНОВКА И РЕШЕНИЕ МНОГОМЕРНОЙ ОПТИМИЗАЦИОННОЙ ЗАДАЧИ

Анализ экспериментальных данных [8] и предварительные исследования [9] дают основания предполагать, что процесс деструкции парацетамола протекает через образование промежуточного продукта, ингибирующего его разложение [10]. В связи с этим была разработана математическая модель, в которой дифференциальные уравнения изменения концентраций субстрата, z -метаболита и биомассы принимают следующий вид:

$$\frac{ds}{dt} = -\frac{\mu_s x}{Y}, \quad (1)$$

$$\frac{dz}{dt} = \frac{\mu_s x}{Y} - \frac{\mu_z x}{Y}, \quad (2)$$

$$\frac{dx}{dt} = \mu_z x, \quad (3)$$

где x – концентрация биомассы (бактерии), г/л;

s – концентрация субстрата (парацетамола), г/л;

z – концентрация промежуточного метаболита, г/л;

t – время процесса, сут.;

μ_s – удельная скорость распада субстрата, 1/сут.;

μ_z – удельная скорость распада z -метаболита, 1/сут.;

$Y = x_{max}/s_0$ – выход биомассы по субстрату, г/г;

s_0 – начальная концентрация субстрата в среде, г/л.

Для описания удельной скорости 1-й стадии принято уравнение Моно с учетом ингибирования этой стадии ее продуктом – z -метаболитом:

$$\mu_s = \frac{\mu_{0s} s}{k_{ss} + s + k_i z}, \quad (4)$$

где μ_{0s} – максимальная удельная скорость распада парацетамола, 1/сут.;

k_{ss} – константа насыщения 1-й стадии, г/л;

k_i – константа ингибирования.

Для описания удельной скорости 2-й стадии (распада z -метаболита) выбрано уравнение Моно без учета какого-либо ингибирования:

$$\mu_z = \frac{\mu_{0z} z}{k_{sz} + z}, \quad (5)$$

где μ_{0z} – максимальная удельная скорость распада z -метаболита, 1/сут.;

k_{sz} – константа насыщения 2-й стадии, г/л.

Проведя анализ полученных результатов, были найдены зависимости удельных скоростей процесса от начальной концентрации субстрата в среде, которые достаточно точно описываются экспоненциальными функциями [10]:

$$\mu_{0s}(s_0) = k_{11} - k_{12} e^{-k_{13} s_0}, \quad \mu_{0z}(s_0) = k_{22} e^{-k_{23} s_0}, \quad (6)$$

где k_{11}, k_{12}, k_{13} – константы уравнения корреляции $\mu_{0s}(s_0)$; k_{22}, k_{23} – константы уравнения корреляции $\mu_{0z}(s_0)$.

Таким образом, оптимизационная задача принимает следующий вид:

$$R(k_{ss}, k_{sz}, k_i, k_{11}, k_{12}, k_{13}, k_{22}, k_{23}) \rightarrow \min. \quad (7)$$

Решением оптимизационной задачи, найденным методом покоординатного спуска при задании случайного начального приближения, стал некий частный набор значений констант: $k_{ss} = 0,04$, $k_{sz} = 0,04$, $k_i = 2,6$, $k_{11} = 0,277$, $k_{12} = 0,233$, $k_{13} = 0,710$, $k_{22} = 0,100$, $k_{23} = 0,920$.

В рамках данной работы авторами была поставлена задача определить, является ли найденное частное решение задачи оптимизации глобальным экстремумом, независимым от случайного фактора погрешности измерений, или это частное решение является частью некоего множества, подчиняющегося определенным закономерностям.

ВЫЧИСЛИТЕЛЬНЫЕ ЭКСПЕРИМЕНТЫ ДЛЯ ОЦЕНКИ ПОЛУЧЕННОГО ЧАСТНОГО РЕШЕНИЯ МНОГОМЕРНОЙ ОПТИМИЗАЦИОННОЙ ЗАДАЧИ

Для качественной и количественной оценки полученного оптимального набора констант проводилась серия вычислительных экспериментов, в ходе которых оптимизационная задача (7) многократно решалась методом покоординатного спуска с помощью задания разных начальных приближений входящих в нее параметров. При этом предварительно было выявлено, что варьирование параметров модели (1)–(6) k_{ss} , k_{sz} , k_i не оказывает существенного влияния на кинетические кривые [10], поэтому в целях упрощения поставленной задачи рассматривалось варьирование начальных приближений только пяти параметров: k_{11} , k_{12} , k_{13} , k_{22} , k_{23} . То есть размерность оптимизационной задачи (7) была понижена с 8 до 5:

$$R(k_{11}, k_{12}, k_{13}, k_{22}, k_{23}) \rightarrow \min. \quad (8)$$

Найденное ранее [10] частное решение оптимизационной задачи (7) было принято «стандартным» и использовалось для оценки степени отклонения результатов оптимизационного алгоритма. Варьирование начальных приближений задавалось с помощью двух подходов: 1) задание единого значения для всех параметров оптимизационной задачи (8), выбранного определенным образом; 2) задание различных значений, выбранных случайным образом в предварительно оцененном диапазоне – с учетом порядка значений «стандартного» решения и на основе ряда вычислительных экспериментов этот диапазон по каждому параметру оптимизационной задачи (8) составил от 0,01 до 2,0. При выборе начальных приближений хотя бы по одному из параметров (8), большему 2, оптимизационный алгоритм мог сталкиваться с проблемой «зацикливания» и необоснованного смещения значений в сторону бесконечного увеличения при том, что это не оказывало заметного влияния непосредственно на значение R . Такие решения не рассматривались, поскольку увеличение значений параметров модели даже на 2–3 порядка фактически означает «вырождение» уравнений (6) в какие-то иные формы. Однако такие вычислительные эксперименты позволили понять, что пятимерная поверхность отклика оптимизационной задачи (8) однозначно имеет овражную структуру и, как следствие, часть параметров будут закоррелированы.

Как и предполагалось, оптимизационный алгоритм столкнулся с многовариантностью решения оптимизационной задачи (8) при задании разных начальных приближений идентифицируемых параметров, то есть частных решений на подобие принятого за «стандарт» бесконечное множество. Далее предстояло определить, подчиняется ли это множество каким-либо общим закономерностям.

Полученные частные решения оптимизационной задачи (8) представлены на рисунке 1 в виде проекций поверхности отклика на параметрические плоскости. На графиках «серыми» точками представлены результаты, полученные при задании начального приближения первым способом, «желтыми» – вторым, а «красный квадрат» – это решение, принятое за «стандарт» (частное решение, описанное в работе [10]). Видно, что между параметрами уравнений (6) существуют зависимости, которые можно описать уравнениями линейной корреляции (рис. 1а) и экспоненциальной функцией (рис. 1б):

$$f_1(k_{11}) = k_{12} = 0,9983k_{11} - 0,046, \quad (9)$$

$$f_2(k_{11}) = k_{13} = 0,088(k_{11} - 0,13)^{-1,05}. \quad (10)$$

Зависимость между параметрами k_{22} и k_{23} , очевидно, более сложная (рис. 1в), но также может быть аппроксимирована с помощью уравнения:

$$f_3(k_{22}) = k_{23} = 1569,9k_{22}^3 - 640,95k_{22}^2 + 89,711k_{22} - 3,2428. \quad (11)$$

При этом следует отметить, что методика выбора начального приближения на полученные корреляции (9)–(11) влияния не оказывает, поэтому можно считать, что они имеют обобщенный характер, а не являются очередным «частным» решением. Следует отметить, что на правом графике (рис. 1в) имеется некий разрыв в области значений k_{22} от 0,14 до 0,15, природу которого на данном этапе установить не удалось, но тем не менее полученные результаты подчиняются единой аппроксимации. Между группами параметров разных уравнений корреляций (9) и (10) с одной стороны и (11) – с другой никаких зависимостей обнаружено не было.

Таким образом, было доказано, что оптимальное решение из [10] действительно является частным, при этом альтернативных решений оптимизационной задачи (8) бесконечное множество. Учитывая величины диапазонов этих альтернативных решений, можно сделать вывод, что их следует рассматривать именно в виде множества, а не единственного решения, на получение которого оказывает влияние выбор начального приближения.

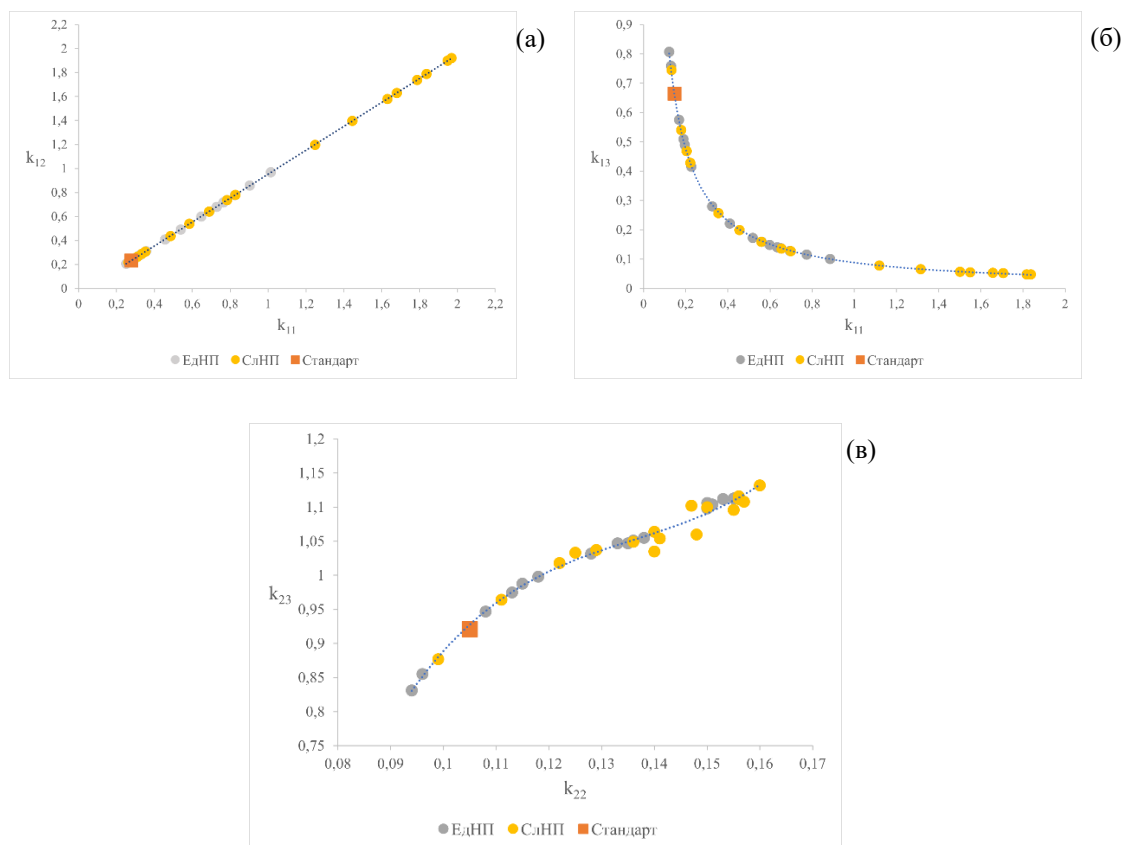


Рисунок 1 – Проекция поверхности отклика на параметрические плоскости: а – $k_{12}=f(k_{11})$, б – $k_{13}=f(k_{11})$, в – $k_{23}=f(k_{22})$

ОЦЕНКА ВЛИЯНИЯ МНОГОВАРИАНТНОСТИ РЕШЕНИЯ ОПТИМИЗАЦИОННОЙ ЗАДАЧИ НА ПРОГНОЗИРОВАНИЕ ПО МОДЕЛИ

На следующем этапе предстояло выяснить, насколько отдельные частные решения оптимизационной задачи (8), получаемые от различных начальных приближений, влияют на прогнозирование по модели. Значимость такого исследования заключается в оценке отличий результатов прогнозирования, которые могли бы быть получены при отсутствии данного комплексного исследования, когда в качестве «единственного» решения оптимизационной задачи могло бы быть получено любое из представленных на рисунке 1.

В качестве «отправной точки» для сравнения результатов был принят частный оптимум, найденный в работе [10]. Критериями оценки были приняты дисперсия адекватности, наибольшее отклонение относительной погрешности при сравнении кинетических кривых, общее время протекания процесса. Для низких концентраций парацетамола, при которых наблюдалась его полная биодеструкция за время эксперимента [8], «время протекания процесса» соответствовало времени достижения расчётной концентрации значения 10^{-3} (т. е. значения ниже порога погрешности измерений), а для высоких концентраций, при которых полного разложения за 10 суток не наблюдается, сравнивалось время достижения концентрации последнего экспериментального замера с погрешностью не более 10^{-5} . Приоритет выбора в качестве критерия «времени протекания процесса» по сравнению с более простым сравнением концентраций в те же моменты времени был отдан по причине того, что именно «время протекания процесса» является в большей степени определяющим фактором планирования при технической реализации любого процесса.

Как показали результаты вычислительных экспериментов, отклонение по дисперсии адекватности для альтернативных решений оптимизационной задачи (8) составляет не более 7 %, при этом среднее значение данного показателя составило 3,6 %, что подтверждается практически полным визуальным наложением кинетических кривых альтернативных решений на «стандарт» (рис. 2).

Отклонение кинетических кривых, численно выраженное абсолютной погрешностью, составило не более 9 % для самой высокой экспериментальной концентрации парацетамола 2,5 г/л, а для остальных – не более 2,8 %. Таким образом, альтернативные решения оптимизационной задачи (8) дают достаточно близкие кинетические кривые.

Однако «время процесса» оказалось более чувствительным к разбросу частных решений оптимизационной задачи (табл.), причём альтернативные прогнозирования протекания процесса могли быть как более быстрыми, так и более медленными, чем «стандарт», но в целом наблюдается тенденция увеличения отличий с ростом концентрации парацетамола. Переход между концентрациями 1,0 г/л и 1,5 г/л в эту тенденцию не вписывается из-за упомянутого выше отличия подхода к оценке «времени процесса» на низких и высоких концентрациях. Так, разброс альтернативных результатов оптимизационной задачи (8) для низких концентраций, когда возможна полная биодеструкция парацетамола, может достигать суток, а для высоких концентраций – двух суток, что может быть существенно при планировании производственных задач.

Таблица – Отклонение численных характеристик нескольких частных решений от «стандарта»

Отличие по дисперсии адекватности, %	Абсолютное отличие «времени процесса» от «стандарта», ч					
	$s_0 = 0,1$ г/л	$s_0 = 0,5$ г/л	$s_0 = 1,0$ г/л	$s_0 = 1,5$ г/л	$s_0 = 2,0$ г/л	$s_0 = 2,5$ г/л
1,72	0,06	2,892	3	1,248	6,804	1,908
1,00	0,096	2,592	3,588	0,516	4,14	1,092
0,45	0,444	0,288	0,036	0,78	1,032	4,548
0,12	1,032	2,256	5,064	0,864	0,372	13,608
1,41	1,632	4,032	11,484	0,108	4,308	22,572
5,63	1,38	7,536	26,04	2,1	9,132	32,676
0,77	0,204	1,584	2,136	0,48	2,532	1,812
6,31	2,604	5,46	20,88	1,248	6,804	1,908
0,39	0,36	3,696	7,512	0,492	2,424	7,692
7,31	1,356	7,716	27,456	1,98	9,552	36,888
0,19	0,336	4,092	8,724	0,576	2,256	10,188
0,51	0,528	1,032	1,488	0,768	1,212	6,072
4,80	2,184	5,496	18,888	1,032	10,044	34,116
7,06	3,048	5,316	22,248	2,676	17,784	40,26
7,34	1,884	7,344	26,184	1,956	10,848	38,1

На рисунке 2 представлено частное решение оптимизационной задачи (8) № 14 из таблицы со следующим набором констант: $k_{11} = 1,01$, $k_{12} = 0,97$, $k_{13} = 0,11$, $k_{22} = 0,2$, $k_{23} = 1,35$. Видно, что представленные значения достаточно сильно отличаются от частного решения из [10], принятого за «стандарт» в данном исследовании. При этом визуальные отличия кинетических кривых достаточно незначительны. Для других частных решений из таблицы эти отличия еще менее заметны. Таким образом, из выбранных для исследования критериев только «время протекания процесса» является значимым для оценки прогностических способностей модели.

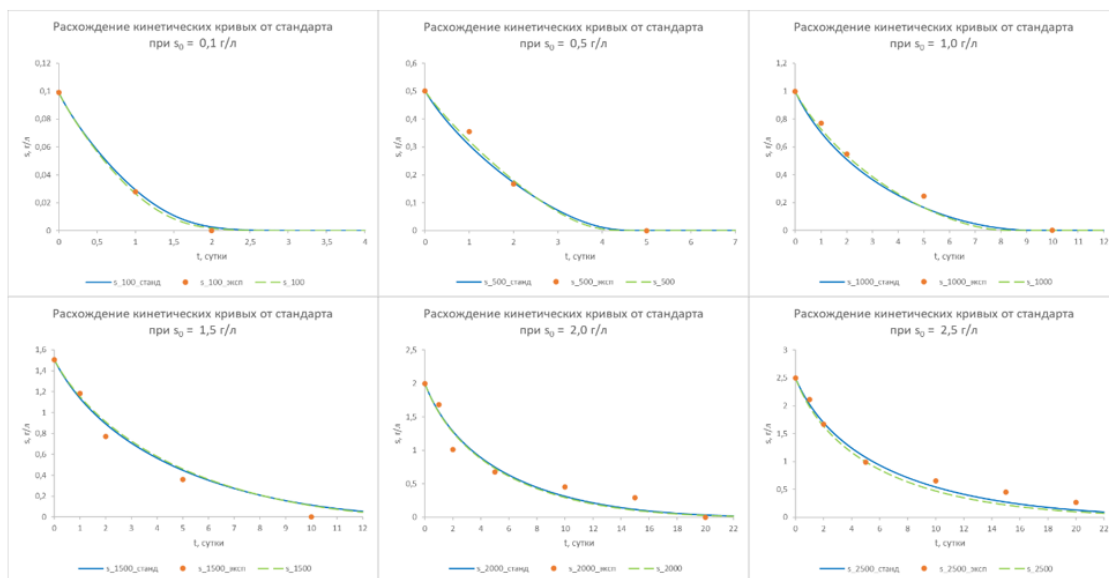


Рисунок 2 – Отклонение кинетических кривых частного решения № 14 от «стандарта»: длинным штрихом отображена кривая, соответствующая частному решению № 14, сплошной линией – «стандарту»

ПОНИЖЕНИЕ РАЗМЕРНОСТИ ОПТИМИЗАЦИОННОЙ ЗАДАЧИ

Наличие множественности альтернативных решений оптимизационной задачи (8) в совокупности с тем, что эти решения не слишком заметно отражаются на кинетических кривых, оставляет открытым вопрос: что же в действительности является решением оптимизационной задачи (8)? Наличие закономерностей (корреляций) между параметрами модели (9)–(11), при которых происходит минимизация критерия R , свидетельствует о наличии «оврага» на пятимерной поверхности отклика $R(k_{11}, k_{12}, k_{13}, k_{22}, k_{23})$, проекции которой были представлены на рисунке 1. Введение корреляций (9)–(11) в оптимизационную задачу (8) позволяет понизить порядок ее размерности:

$$R(k_{11}, k_{12}, k_{13}, k_{22}, k_{23}) = R(k_{11}, f_1(k_{11}), f_2(k_{11}), k_{22}, f_3(k_{22})) \rightarrow \min, \quad (12)$$

или, более кратко,

$$R(k_{11}, k_{22}) \rightarrow \min. \quad (13)$$

Таким образом, с использованием корреляций (9)–(11) пятимерная оптимизационная задача (8) становится двумерной (13), что позволяет анализировать ее поверхность отклика с помощью наглядных инструментов (рис. 3).




Рисунок 3 – Поверхность отклика двумерной оптимизационной задачи (13)

Рисунок 3 показывает, что на двумерной поверхности отклика (13) существует глобальный экстремум, соответствующий набору констант: $k_{11} = 0,315, k_{22} = 0,111$. Значения остальных констант математической модели будут определяться по соотношениям (9)–(11): $k_{12} = 0,268, k_{13} = 0,518, k_{23} = 0,965$. Следует отметить, что получение глобального экстремума было бы невозможно без выявления корреляций (9)–(11), поэтому можно считать, что они также являются частью решения исходной оптимизационной задачи (8) идентификации параметров математической модели биоразложения парацетамола (1)–(6).

ЗАКЛЮЧЕНИЕ

Таким образом, на примере задачи идентификации параметров математической модели процесса разложения парацетамола было показано, что многовариантность решения оптимизационной задачи идентификации параметров математической модели может быть преодолена путем выявления корреляций между искомыми параметрами модели. Однако в данной работе также было показано, что случайные частные решения оптимизационной задачи в данном случае не слишком сильно влияют на демонстрацию кинетики процесса по модели, если при этом принимать во внимание допустимую погрешность оценки времени его протекания, которую необходимо учитывать при проектировании рассматриваемого процесса в реальных условиях.

Список источников

1. Apreja, M. Antibiotic residues in environment: antimicrobial resistance development, ecological risks, and bioremediation / M. Apreja, A. Sharma, S. Balda et al. // *Environmental Science and Pollution Research*. – 2022. – Vol. 29, № 3. – P. 3355–3371.
2. Rastogi, A. A review on environmental occurrence, toxicity and microbial degradation of Non-Steroidal Anti-Inflammatory Drugs (NSAIDs) / A. Rastogi, M. K. Tiwari, M. M. Ghangrekar // *Journal of Environmental Management*. – 2021. – Vol. 300. – P. 113694.
3. Черноруцкий, И. Г. Алгоритмические проблемы жесткой оптимизации / И. Г. Черноруцкий // *Информатика, телекоммуникации и управление*. 2012. № 6 (162). С. 141–152.
4. Рыков, А. С. Недифференцируемые овражные двумерные тест-функции / А. С. Рыков, М. Ю. Матвиенко // *Проблемы управления*. 2008. № 4. С. 16–19.
5. Рыков, А. С. Недифференцируемые овражные трехмерные, четырехмерные и многомерные оптимизационные тест-функции / А. С. Рыков, М. Ю. Матвиенко // *Идентификация систем и задачи управления (SICPRO '09)*. – 2009. – С. 273–278.
6. Черноруцкий, И. Г. Петербургская научная школа жесткой оптимизации (история и обзор основных научных результатов) / И. Г. Черноруцкий // *Информатика, телекоммуникации и управление*. – 2013. № 5 (181). – С. 29–38.
7. Zeng, G. Q. Multistage extremal optimization for hard travelling salesman problem / G. Q. Zeng, Y. Z. Lu, W. J. Mao // *Physica A: Statistical Mechanics and its Applications*. – 2010. – Vol. 389, № 21. – P. 5037–5044.
8. Chopra, S. Biodegradation and kinetic analysis of acetaminophen with co-culture of bacterial strains isolated from sewage wastewater / S. Chopra, D. Kumar // *Current Microbiology*. – 2020. – Vol. 77, № 10. – P. 3147–3157.
9. Кожухарь, О. Ю. Исследование допустимости использования уравнения Холдейна для описания изменения удельной скорости процесса биоразложения парацетамола / О. Ю. Кожухарь, Е. А. Дружкина, А. С. Скичко // *Успехи в химии и химической технологии*. – 2023. – Т. 37, № 11. – С. 81–84.
10. Кожухарь, О. Ю. Математическое моделирование процесса биоразложения парацетамола и анализ особенностей решения оптимизационной задачи определения параметров модели / О. Ю. Кожухарь, А. С. Скичко // *Прикаспийский журнал: управление и высокие технологии*. – 2025. – № 1 (69).

References

1. Apreja, M., Sharma, A., Balda, S. et al. Antibiotic residues in environment: antimicrobial resistance development, ecological risks, and bioremediation. *Environmental Science and Pollution Research*, 2022, vol. 29, no. 3, pp. 3355–3371.
2. Rastogi, A., Tiwari, M. K., Ghangrekar, M. M. A review on environmental occurrence, toxicity and microbial degradation of Non-Steroidal Anti-Inflammatory Drugs (NSAIDs). *Journal of Environmental Management*, 2021, vol. 300, p. 113694.
3. Chernorutskiy, I. G. Algorithmic problems of rigorous optimization. *Informatics, Telecommunications and Management*, 2012, no. 6 (162), pp. 141–152 (In Russ.).
4. Rykov, A. A., Matvienko, M. Yu. Non-differentiable 2-d ravine test functions. *Management Issues*, 2008, no. 4, pp. 16–19 (In Russ.).
5. Rykov, A. A., Matvienko, M. Yu. Non differentiable optimisation three-dimensional, four dimensional and multidimensional valley test-functions. *System identification and control problems (SICPRO '09)*, 2009, pp. 273–278 (In Russ.).
6. Chernorutskiy, I. G. St. Petersburg scientific school of stiff optimization (history and review of main scientific results). *Informatics, Telecommunications and Management*, 2013, no. 5 (181), pp. 29–38 (In Russ.).
7. Zeng, G. Q., Lu, Y. Z., Mao, W. J. Multistage extremal optimization for hard travelling salesman problem. *Physica A: Statistical Mechanics and its Applications*, 2010, vol. 389, no. 21. pp. 5037–5044.
8. Chopra, S., Kumar, D. Biodegradation and kinetic analysis of acetaminophen with co-culture of bacterial strains isolated from sewage wastewater. *Current Microbiology*, 2020, vol. 77, no. 10, pp. 3147–3157.
9. Kozhukhar, O. Yu., Druzhkina, E. A., Skichko, A. S. Investigation of the acceptability of using the Haldane equation to describe the change in the specific rate of paracetamol biodegradation process. *Advances in Chemistry and Chemical Technology*, 2023, vol. 37, no. 11, pp. 81–84 (In Russ.).
10. Kozhukhar, O. Yu., Skichko, A. S. Mathematical modelling of paracetamol biodegradation process and analysis of the peculiarities of solving the optimisation problem of determining the model parameters. *Caspian Journal: Control and High Technologies*, 2025, no. 1 (69) (In Russ.).

Статья поступила в редакцию 01.05.2025; одобрена после рецензирования 25.07.2025; принята к публикации 04.08.2025.

The article was submitted 01.05.2025; approved after reviewing 25.07.2025; accepted for publication 04.08.2025.

УДК 004.043, 004.42

СОЗДАНИЕ ЦИФРОВОГО АССИСТЕНТА С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИИ TELEGRAM-БОТА

Калинина Юлия Юрьевна, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а,

студент по направлению «Информационные системы и технологии» кафедры информационных технологий, ORCID: 0009-0009-8785-4634, e-mail: jilietka@mail.ru

Лебедева Кристина Евгеньевна, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а,

студент по направлению «Информационная безопасность» кафедры информационной безопасности, ORCID: 0009-0001-8678-3397, e-mail: klebedeva14052003@gmail.ru

Смирнова Юлия Александровна, Астраханский государственный университет им. В. Н. Татищева, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а,

старший преподаватель кафедры информационных технологий, ORCID: 0000-0002-3807-5062, e-mail: got-22@mail.ru

В статье рассмотрена техническая проблема взаимодействия между подразделениями внутри предприятия. Особое внимание уделяется автоматизации работы HR-отдела, в частности оптимизации процессов взаимодействия между сотрудниками при оформлении документов, таких как: справки с места работы, информации об отпуске и др. Взаимодействие между сотрудниками и HR-отделом может быть неэффективным из-за необходимости личного присутствия или использования устаревших систем связи, таких как электронная почта или бумажные документы. Тратится значительное количество времени на обработку и оформление документов, что снижает общую производительность, а ручные процессы более подвержены ошибкам, приводя к неточностям в документах и дополнительным затратам на их исправление, что ухудшает качество обслуживания сотрудников, негативно сказываясь на их удовлетворенности и лояльности к компании, и в итоге может привести к увеличению затрат и падению общей производительности компании. Предлагается разработка информационной системы, использующей технологию «API Telegram» для автоматизации простых запросов и выгрузки документов. Цель данной разработки – сокращение времени, затрачиваемого на оформление заявления, повышение качества обслуживания сотрудников организации, что в конечном итоге приведет к снижению затрат и повышению производительности работы компании.

Ключевые слова: hr-менеджер, Telegram, чат-бот, мессенджер, автоматизация, оптимизация рабочих процессов

CREATION OF A DIGITAL ASSISTANT USING TELEGRAM BOT TECHNOLOGY

Kalinina Yulia Yu., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

student in the field of Information Systems and Technologies of the Department of Information Technology, ORCID: 0009-0009-8785-4634, e-mail: jilietka@mail.ru

Lebedeva Kristina E., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

student in the field of Information Security at the Department of Information Security, ORCID: 0009-0001-8678-3397, e-mail: klebedeva14052003@gmail.ru

Smirnova Yulia A., Astrakhan Tatishchev State University, 20a Tatishchev St., Astrakhan, 414056, Russian Federation,

Senior Lecturer of the Department of Information Technology, ORCID: 0000-0002-3807-5062, e-mail: got-22@mail.ru

The article considers the technical problem of interaction between departments within the enterprise. Special attention is paid to automating the work of the HR department, in particular, optimizing the processes of interaction between employees when processing documents, such as certificates from the workplace, vacation information, and others. Interaction between employees and the HR department may be ineffective due to the need for personal presence or the use of outdated communication systems such as email or paper documents. A significant amount of time is spent on processing and processing documents, which reduces overall productivity, and manual processes are more error-prone, leading to inaccuracies in documents and additional costs for correcting them, which worsens the quality of service for employees, negatively affecting their satisfaction and loyalty to the company, and may eventually lead to increased costs and a drop in the overall performance of the company. It is proposed to develop an information system using the Telegram API technology to automate simple requests and document uploads. The purpose of this development is to reduce the time spent on application processing, improve the quality of service to the organization's employees, which ultimately leads to lower costs and increased productivity of the company.

Keywords: HR manager, Telegram, chatbot, messenger, automation, workflow optimization

ВВЕДЕНИЕ

HR-менеджер (Human Resources Manager) – это специалист по управлению персоналом, который выступает связующим звеном между руководством компании и сотрудниками. В современных организациях HR-менеджер выполняет стратегически важную функцию, обеспечивая оптимальное использование трудовых ресурсов для реализации корпоративных задач [1]. Его работа охватывает широкий спектр задач: от кадрового документооборота до стратегического управления персоналом. Однако рутинные операции часто отнимают более 50 % рабочего времени, снижая эффективность стратегической работы.

Ежедневно HR-специалист сталкивается с необходимостью обработки множества обращений от сотрудников. Оформление кадровых документов требует последовательного выполнения строго регламентированных действий. Например, процесс подготовки расчетного листа включает пять обязательных этапов:

1. Сотрудник обращается непосредственно к HR-менеджеру.
2. HR-менеджер собирает необходимые документы для оформления расчетного листа сотрудника.
3. HR-менеджер передает собранный пакет документов в отдел бухгалтерии.
4. Отдел бухгалтерии формирует документ и оповещает о готовности сотруднику.
5. Сотрудник забирает документ (забрать документ имеет право непосредственно сотрудник при очном обращении с отдел).

Не менее важна функция контроля отпусков, где HR-менеджер выступает посредником между сотрудником и кадровой службой. Этот процесс включает четыре последовательных шага:

1. Получить просьбу о выполнении задачи от сотрудника.
2. Связаться с отделом кадров и передать необходимые данные сотрудника.
3. Получить ответ от отдела кадров.
4. Оповестить сотрудника о готовности ответа.

Ручная обработка запросов создает несколько существенных проблем. Временные затраты значительно возрастают из-за необходимости личного взаимодействия на каждом этапе. Вероятность ошибок при ручном вводе данных снижает общую эффективность процессов, и время выполнения требуемого процесса значительно увеличивается. Для сотрудников удаленных форматов работы особенно остро стоит вопрос оперативного доступа к HR-услугам. Основные временные затраты, с которыми сталкивается менеджер по персоналу, представлены на рисунке 1.




Рисунок 1 – Диаграмма «Основные потери времени HR-менеджера»

Анализ текущей работы выявляет несколько ключевых сложностей процесса [2]. Бумажный документооборот создает риски потери или задержки важных документов. Необходимость личного присутствия сотрудников для получения справок существенно замедляет процессы. Постоянные повторяющиеся запросы отнимают время, которое возможно направить на развитие персонала. Грамотное и быстрое взаимодействие между подразделениями подразумевает эффективную работу компании за счет оперативной передачи информации по каналам коммуникации, а также возникновение новых способов решений проблем.

АВТОМАТИЗАЦИЯ И ОПТИМИЗАЦИЯ БИЗНЕС-ПРОЦЕССОВ С ПОМОЩЬЮ ЧАТ-БОТОВ

Сегодня общение между сотрудниками происходит в программах для мгновенного обмена текстовыми сообщениями (мессенджеры). Использование мессенджеров обусловлено способностью обеспечивать оперативный обмен информацией, независимо от расстояния или других ограничений, которые могут существовать между участниками коммуникации [3]. Это особенно важно в условиях глобализации и удаленной работы, где сотрудники могут находиться в разных частях мира. В связи с этим свое быстрое развитие получили так называемые «чат-боты», которые позволяют сэкономить время на поиске нужного ресурса. Чат-бот может вести коммуникацию от разных компаний, с целью упростить онлайн-общение.

Чат-боты стали неотъемлемой частью корпоративной культуры, предлагая широкий спектр функциональных возможностей, которые способны обрабатывать типовые запросы сотрудников, начиная от предоставления информации о внутренних процессах компании и заканчивая автоматизацией рутинных задач. Это позволяет не только повысить эффективность работы, но и освободить время сотрудников для выполнения более сложных и творческих задач. Внедрение чат-бота в корпоративную среду способствует оптимизации рабочих процессов и улучшению взаимодействия между подразделениями.

Одной из ключевых областей применения ботов является автоматизация документооборота, в частности процесс формирования расчетных листов, что существенно сокращает время на выполнение рутинной задачи. Сотрудник отправляет запрос через мессенджер Telegram и мгновенно получает готовый расчетный лист в формате PDF. Это не только упрощает процесс, но и минимизирует риск ошибок, связанных с человеческим фактором [4].

Важным аспектом использования системы является обеспечение безопасности персональных данных сотрудников организации. Реализация данного функционала осуществляется в соответствии с требованиями Федерального закона «О персональных данных» от 27.07.2006 № 152-ФЗ [5], Трудовым кодексом Российской Федерации от 30.12.2001 № 197-ФЗ [6], а также должностными инструкциями работников организации. Обработка персональных данных осуществляется с согласия субъекта и в рамках трудовых отношений. Система предусматривает применение современных методов шифрования данных при хранении и передаче, а также многоуровневую систему контроля доступа, исключающую несанкционированный доступ к конфиденциальной информации.

Для оценки встраиваемости чат-бота в рабочие процессы необходимо рассмотреть взаимодействие с пользователями и внешними системами. Чат-бот выступает посредником между сотрудником и корпоративными сервисами. Пользователь отправляет запрос через мессенджер, бот обрабатывает его, при необходимости обращается к внешним API или базам данных и возвращает ответ в корректном формате. Пример потоков данных, реализованных в рамках проектирования системы, возможно изобразить в виде диаграммы в нотации IDEF0, которая представлена на рисунке 2.

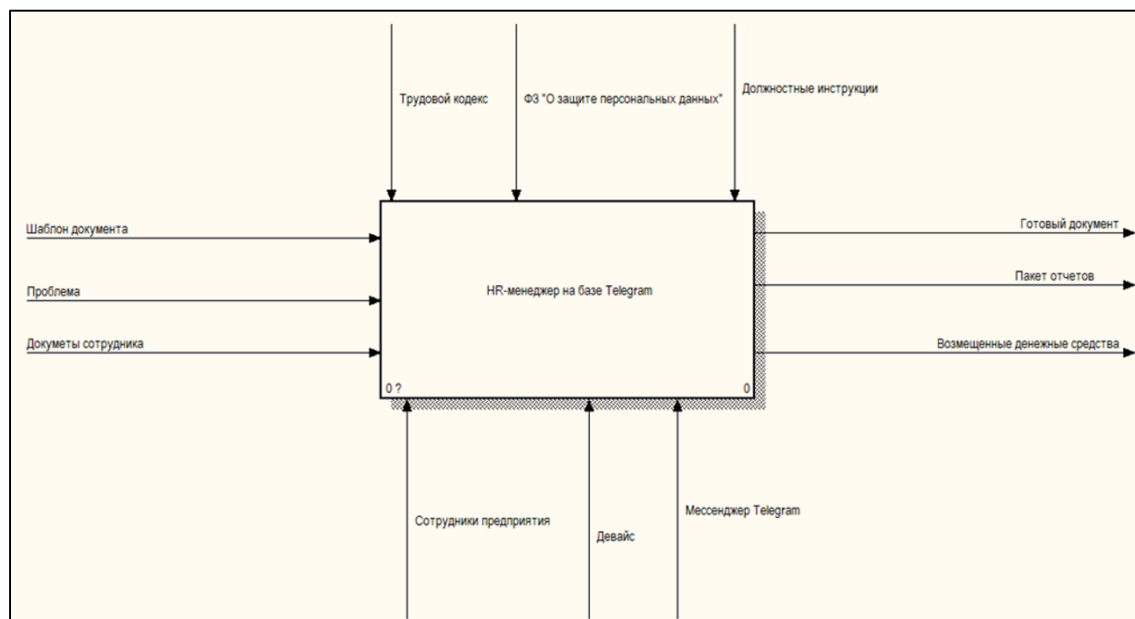


Рисунок 2 – Контекстная модель ИС «HR-менеджер на базе Telegram»

Интеграция чат-бота в рабочие процессы позволяет не только автоматизировать рутинные задачи, но и значительно повысить скорость и точность обработки запросов, что способствует улучшению взаимодействия между сотрудниками и подразделениями, а также оптимизации использования корпоративных ресурсов. Внедрение чат-ботов открывает новые возможности для цифровизации бизнес-процессов и повышения общей эффективности работы компании.

АРХИТЕКТУРА ПРОЕКТА

Для наглядного представления технической архитектуры проекта была разработана схема, иллюстрирующая последовательность выполнения работ и перечень необходимого программного обеспечения (рис. 3).

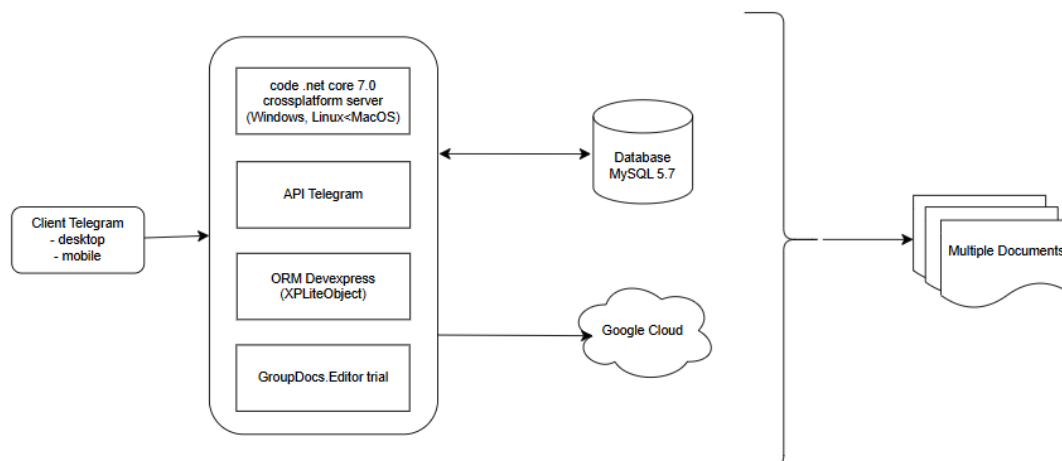


Рисунок 3 – Техническая архитектура проекта

Схема архитектуры системы представляет собой многоуровневый стек приложений. «Client Telegram» (установленные на компьютере или мобильная версия) взаимодействует с базовой логикой приложения, находящейся на уровне сервера. Сервер состоит из следующих компонентов:

- кроссплатформенный сервер .Net Core 7.0, предоставляющий среду выполнения, поддерживающий развертывание в операционных системах, таких как Windows, Linux, MacOS;
- модуль «API Telegram», который облегчает взаимодействие с платформой обмена сообщениями Telegram;
- инструмент ORM Devexpress (XPLiteObject), обеспечивающий объектно-реляционное отображение для оптимизированного взаимодействия с базой данных [7];
- GroupDocs.Editor trial – компонент для удобного редактирования, перевода и сохранения документов различного формата [8].

Сохранение и хранение данных осуществляется с помощью базы данных MySQL 5.7 [9], выступающего в качестве структурированного репозитория данных, и Google Cloud, выступающего в качестве масштабируемого облачного решения для хранения неструктурированных или двоичных данных.

При выборе MySQL в качестве СУБД учитывались следующие преимущества: высокая производительность, возможность использования на различных платформах, совместимость с .Net Core, а также открытый исходный код [10].

На схеме показан двунаправленный поток данных между сервером .NET Core и базой данных MySQL, обозначенный двунаправленной стрелкой. Это говорит о том, что сервер как считывает, так и записывает данные в базу данных для операций извлечения и изменения данных.

Заключительный этап включает в себя генерацию и обработку нескольких документов, полученных из базы данных или из хранилища Google Cloud.

Для реализации информационной системы был выбран язык программирования C#. Одними из преимуществ данного языка программирования являются [11]: оперативная интеграция C# с платформами .NET Framework и .NET Core, кроссплатформенность, асинхронное программирование, тип безопасности.

Таким образом, данный проект представляет собой сложный процесс, который включает в себя структурированные и неструктурированные данные на основе методов системного анализа, таких как метод оценки рисков, кластеризации и классификации, методы экспертного оценивания и тестирования:

1. Метод оценки рисков. Оценка риска связана с вероятностью сбоя в системе, что может привести к потере данных.
2. Метод кластеризации и классификации. Анализ отзывов сотрудников об использовании системы для выявления основных проблем в работе и использовании чат-бота.
3. Метод экспертного оценивания. Оценка возможных рисков при внедрении системы.
4. Тестирование. Проверка соответствия каждой функции системы заданным требованиям.

Применение данных методов приведет к улучшению обработки информации в данной сфере, повышению эффективности принятия решений, оптимизации бизнес-процессов и в конечном итоге к достижению поставленных целей.

ФУНКЦИОНАЛЬНЫЕ ВОЗМОЖНОСТИ СИСТЕМЫ

При входе в публичный чат-бот любой пользователь имеет доступ к меню, состоящему из следующих функций:

1. Информация о вакансиях. На вход системы подается запрос /jobs, который предоставляет информацию о свободных вакансиях. Ответ сообщает, есть ли в данный момент свободные вакансии (рис. 4).



Рисунок 4 – Информация о вакансиях

2. Документы для приема на работу. На вход подается запрос /documents/. Данный запрос предоставляет информацию о документах, которые необходимы для приема на работу. На выходе получаем список документов, в который входит: паспорт, регистрация по месту пребывания, трудовая книжка, ИНН и пенсионное свидетельство, документы для воинского учета, дипломы и свидетельства, медицинская книжка (рис. 5).

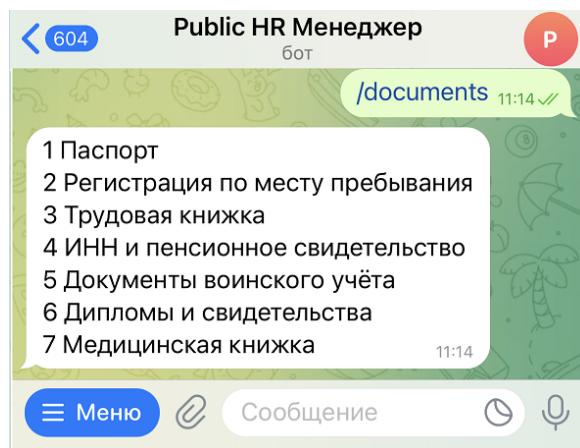


Рисунок 5 – Информация о документах для приема на работу

3. Информация об организации. На вход прописываем запрос /info. На выходе получаем информацию об организации, а именно ИНН и ОКВЭД организации (рис. 6).




Рисунок 6 – Информация об организации

При входе во внутренний чат-бот требуется нажать на кнопку «Начать», далее отправляем команду /start и начинается работа с ботом.

Во внутреннем чат-боте доступны следующие функции:

1. Получение документов на компенсацию. Подаем в бот запрос /compensation. Бот предлагает два варианта получения бланка заявления на компенсацию – PDF и DOC, выбираем наиболее подходящий (рис. 7).

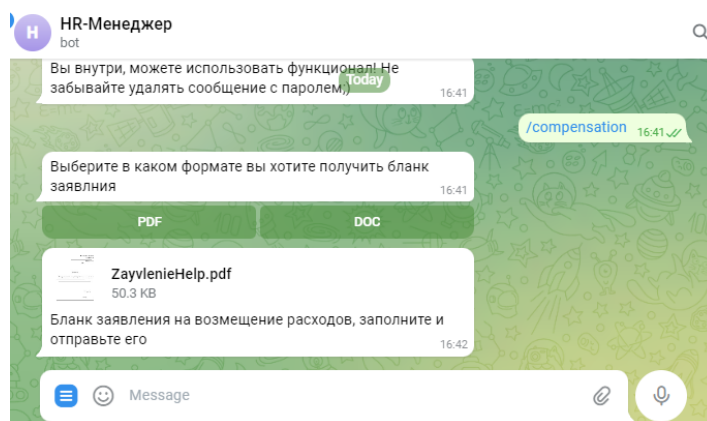


Рисунок 7 – Информация о документе по компенсации

2. Формирование расчетного листа сотрудника. В боте прописываем запрос /payslip. Данный запрос на выходе выдает бланк расчетного листа в формате DOC (рис. 8).




Рисунок 8 – Документ «Расчетный лист»

3. Получение информации о дате начала отпуска и остатке полных дней с момента выхода в отпуск. Для получения информации о дате начала отпуска и количестве оставшихся полных дней необходимо отправить запрос /days. В ответ получаем информацию о дате отпуска и количестве оставшихся дней до его начала, а также бланк для заполнения заявления на отпуск (рис. 9).

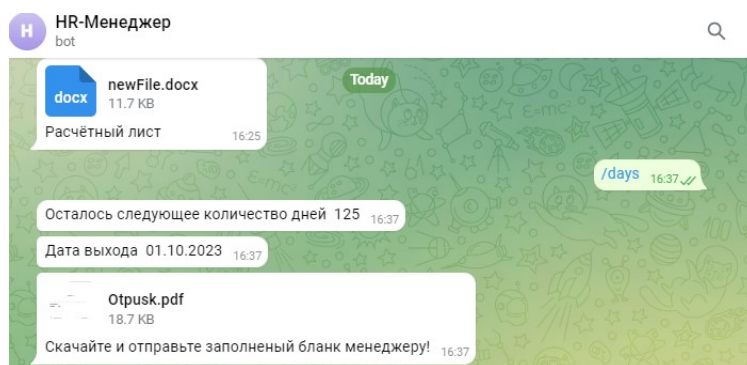


Рисунок 9 – Информация об отпуске

4. Получение справки с места работы. Для получения данной справки необходимо отправить чат-боту запрос /workinfo (рис. 10).

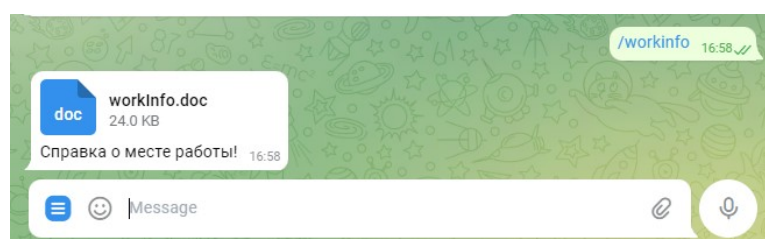


Рисунок 10 – Документ «Справка с места работы»

Автоматизация HR-процессов через Telegram-бота значительно ускоряет получение документов и информации для сотрудников. Также снижается нагрузка на HR-отдел, который занимается данными задачами.

ЗАКЛЮЧЕНИЕ

Активное использование цифровых технологий, в частности мессенджеров и чат-ботов, позволяет существенно оптимизировать коммуникационные процессы и автоматизировать рутинные задачи в компаниях. Разработанная концепция автоматизации HR-процессов с использованием «API Telegram» представляет собой перспективный подход к повышению удобства для сотрудников, снижению нагрузки на HR-отдел и оптимизации документооборота. Внедрение таких технологий способствует ускорению обработки запросов, а также улучшению качества предоставляемых услуг, что в конечном итоге ведет к повышению общей эффективности работы компании.

Дальнейшие исследования направлены на практическое применение и усовершенствование системы, а также на экономическую составляющую от разработки предложенного проекта. Важно оценивать не только технические аспекты внедрения чат-ботов, но и их влияние на бизнес-процессы в целом. Это включает в себя анализ затрат на разработку и внедрение системы, а также оценку потенциальной экономии времени и ресурсов, что позволит определить рентабельность проекта.

Список источников

1. Дронова, А. М. Использование виртуальных HR-ассистентов и чат-ботов в управлении персоналом: преимущества и недостатки / А. М. Дронова // Гуманитарный научный журнал. – 2025. – № 3–2. – С. 28–35. – DOI 10.24412/2078-9661-2025-3-2-2. – EDN FNNJRU.
2. Автоматизация HR-процессов бизнеса // Контур. – URL: https://kontur.ru/articles/52924-avtomatizaciya_hr_processov_biznesa.
3. Зуева, З. В. Использование цифровых технологий в управлении персоналом / З. В. Зуева, Ю. А. Катровский // Бизнес-образование в экономике знаний. – 2021. – № 2 (19). – С. 64–68. – EDN VZSJHT.
4. Дронова, А. М. Использование виртуальных HR-ассистентов и чат-ботов в управлении персоналом: преимущества и недостатки / А. М. Дронова // Гуманитарный научный журнал. – 2025. – № 3–2. – С. 28–35. – DOI 10.24412/2078-9661-2025-3-2-2. – EDN FNNJRU.
5. Федеральный закон «О персональных данных» от 27.07.2006 № 152-ФЗ // КонсультантПлюс. – URL: https://www.consultant.ru/document/cons_doc_LAW_61801/.
6. Трудовой кодекс Российской Федерации от 30.12.2001 № 197-ФЗ // КонсультантПлюс. – URL: https://www.consultant.ru/document/cons_doc_LAW_34683/.
7. eXpress Persistent Objects (XPO) // DevExpress. – URL: <https://www.devexpress.com/products/net/orm/>.
8. GroupDocs Editor // GroupDocs. – URL: <https://products.groupdocs.com/ru/editor/>.

9. MySQL: преимущества и недостатки // Timeweb.Cloud. – URL: <https://timeweb.cloud/blog/mysql-preimushchestva-i-nedostatki>.

10. Громов, Н. Д. Сравнение популярных решений РСУБД / Н. Д. Громов, А. И. Платошин // Моя профессиональная карьера. – 2023. – Т. 3, № 55. – С. 119–124. – EDN LCAVZB.

11. Албахари, Дж. С# 6.0. Справочник. Полное описание языка / Дж. Албахари, Б. Албахари. – Москва : Вильямс, 2016. – 1040 с.

References

1. Dronova, A. M. The use of virtual HR assistants and chatbots in personnel management: advantages and disadvantages. *Humanitarian Scientific Journal*, 2025, no. 3–2, pp. 28–35. DOI 10.24412/2078-9661-2025-3-2-2. EDN FNNJRU (In Russ.).

2. Automation of HR business processes. *Contour*. Available at: https://kontur.ru/articles/52924-avtomatizaciya_hr_processov_biznesa (In Russ.).

3. Zueva, Z. V., Katrovsky Yu. A. The use of digital technologies in personnel management. *Business Education in the Knowledge Economy*, 2021, no. 2 (19), pp. 64–68. EDN VZSJHT (In Russ.).

4. Dronova, A. M. The use of virtual HR assistants and chatbots in personnel management: advantages and disadvantages. *Humanitarian Scientific Journal*, 2025, no. 3–2, pp. 28–35. DOI 10.24412/2078-9661-2025-3-2-2. EDN FNNJRU (In Russ.).

5. Federal Law "On Personal Data" dated 27.07.2006 no. 152-FZ. *ConsultantPlus*. Available at: https://www.consultant.ru/document/cons_doc_LAW_61801/ (In Russ.).

6. The Labor Code of the Russian Federation dated 12/30/2001 N 197-FZ. *ConsultantPlus*. Available at: https://www.consultant.ru/document/cons_doc_LAW_34683/ (In Russ.).

7. eXpress Persistent Objects (XPO). *DevExpress*. Available at: <https://www.devexpress.com/products/net/orm/>.

8. GroupDocs Editor. *GroupDocs*. Available at: <https://products.groupdocs.com/ru/editor/>

9. MySQL: advantages and disadvantages. *Timeweb.Cloud*. Available at: <https://timeweb.cloud/blog/mysql-preimushchestva-i-nedostatki> (In Russ.).

10. Gromov, N. D., Platoshin A. I. Comparison of popular RDBMS solutions. *My Professional Career*, 2023, vol. 3, no. 55, pp. 119–124. EDN LCAVZB (In Russ.).

11. Albakhari, J. Albahari, B. С# 6.0. Reference book. Full description of the language. Moscow, Williams, 2016. 1040 p. (In Russ.).

Статья поступила в редакцию 15.05.2025; одобрена после рецензирования 14.07.2025; принята к публикации 14.07.2025.

The article was submitted 15.05.2025; approved after reviewing 14.07.2025; accepted for publication 14.07.2025.

УДК 004.422.8

**ПРОГРАММНАЯ СИСТЕМА АНАЛИЗА РЕЗУЛЬТАТОВ МОДЕЛИ
ГЛУБОКОГО ОБУЧЕНИЯ НА ПРИМЕРЕ ИЗОБРАЖЕНИЙ
ЯДРОСОДЕРЖАЩИХ КЛЕТОК ИЗ ПРЕПАРАТОВ КОСТНОГО МОЗГА**

Поляков Евгений Валерьевич, Национальный исследовательский ядерный университет «МИФИ», 115409, Российская Федерация, г. Москва, Каширское шоссе, 31,
кандидат технических наук, доцент кафедры медицинской физики, ORCID: 0000-0002-5346-6504, e-mail: EVPolyakov@mephi.ru

Дорошин Сергей Юрьевич, Национальный исследовательский ядерный университет «МИФИ», 115409 Российская Федерация, г. Москва, Каширское шоссе, 31,
аспирант кафедры компьютерных систем и технологий, ORCID: 0009-0007-6729-7418, e-mail: sergejdoroshin99@gmail.com

Филатова Нелли Анатольевна, ФГБУ НМИЦ онкологии имени Н.Н. Блохина МЗ РФ, 115522, Российская Федерация, г. Москва, Каширское шоссе, 24,
врач клинической лабораторной диагностики централизованного научно-клинического лабораторного отдела, e-mail: filatova.nelli@gmail.com

Дмитриева Валентина Викторовна, Национальный исследовательский ядерный университет «МИФИ», 115409 Российская Федерация, г. Москва, Каширское шоссе, 31,
кандидат технических наук, доцент кафедры электрофизических установок, ORCID: 0000-0002-9202-6691, e-mail: VVDmitriyeva@mephi.ru

Климанов Игорь Александрович, ФГБУ НМИЦ онкологии имени Н.Н. Блохина МЗ РФ, 115522, Российская Федерация, г. Москва, Каширское шоссе, 24,
кандидат медицинских наук, заведующий централизованного научно-клинического лабораторного отдела, ORCID: 0000-0001-8593-1098, e-mail: IgorKlimanov@yandex.ru

Несмотря на попытки автоматизации микроскопического анализа, по-прежнему в основном выполняется вручную, что требует высокой квалификации врача и может приводить к ошибкам, низкой скорости работы и недостаточной точности. Таким образом, разработка новых программных инструментов для анализа изображений ядросодержащих клеток остается актуальной задачей. В работе представлена разработка программной системы для анализа результатов модели глубокого обучения, ориентированной на автоматизацию аннотирования ядросодержащих клеток, полученных с изображений препаратов костного мозга, автоматизированным анализатором биомедицинских изображений. Система включает в себя инструменты для разметки данных, анализа качества обучения модели и инференса, обеспечивая кроссплатформенность и независимость от конкретных фреймворков машинного обучения. Программное обеспечение реализовано с использованием языка C++, фреймворка Qt, библиотеки OpenCV и ONNX Runtime. Экспериментальные исследования, проведенные в рамках работы, показали высокие показатели согласованности обученной модели с коэффициентом Каппа в диапазоне от 71 до 94 %. Результаты анализа изображений гемопоэтических клеток костного мозга показали точность 92 % при сравнении с данными эксперта. Разработанная система позволяет минимизировать нагрузку на специалистов, обеспечивая предварительную разметку данных и упрощая процесс проверки и корректировки. Результаты работы могут быть использованы не только для разметки данных и анализа качества моделей, но и для обнаружения объектов других типов.

Ключевые слова: компьютерное зрение, глубокое обучение, компьютерная микроскопия, разметка данных, изображения ядросодержащих клеток

**A SOFTWARE SYSTEM FOR ANALYZING THE RESULTS OF A DEEP LEARNING MODEL
USING IMAGES OF NUCLEATED CELLS FROM BONE MARROW PREPARATIONS**

Polyakov Evgeniy V., National Research Nuclear University «MEPhI» (Moscow Engineering Physics Institute), 31 Kashirskoye shosse, Moscow, 115409, Russian Federation,

Cand. Sci. (Engineering), Associate Professor of the Department of Medical Physics, ORCID: 0000-0002-5346-6504, e-mail: EVPolyakov@mephi.ru

Doroshin Sergey Yu., National Research Nuclear University «MEPhI» (Moscow Engineering Physics Institute), 31 Kashirskoye shosse, Moscow, 115409, Russian Federation,

graduate student of the Department of Computer Systems and Technologies, e-mail: sergejdoroshin99@gmail.com

Filatova Nelli A., N.N. Blokhin National Medical Research Center of Oncology, Ministry of Health of the Russian Federation, 31 Kashirskoye shosse, Moscow, 115409, Russian Federation,

Doctor of Clinical Laboratory Diagnostics of the Centralized Scientific and Clinical Laboratory Department, e-mail: filatova.nelli@gmail.com

Dmitrieva Valentina V., National Research Nuclear University «MEPhI» (Moscow Engineering Physics Institute), Russian Federation, 31 Kashirskoye shosse, Moscow, 115409, Russian Federation,

Cand. Sci. (Engineering), Associate Professor of the Department of Electrophysical Installations, ORCID: 0000-0002-9202-6691, e-mail: VVDmitriyeva@mephi.ru

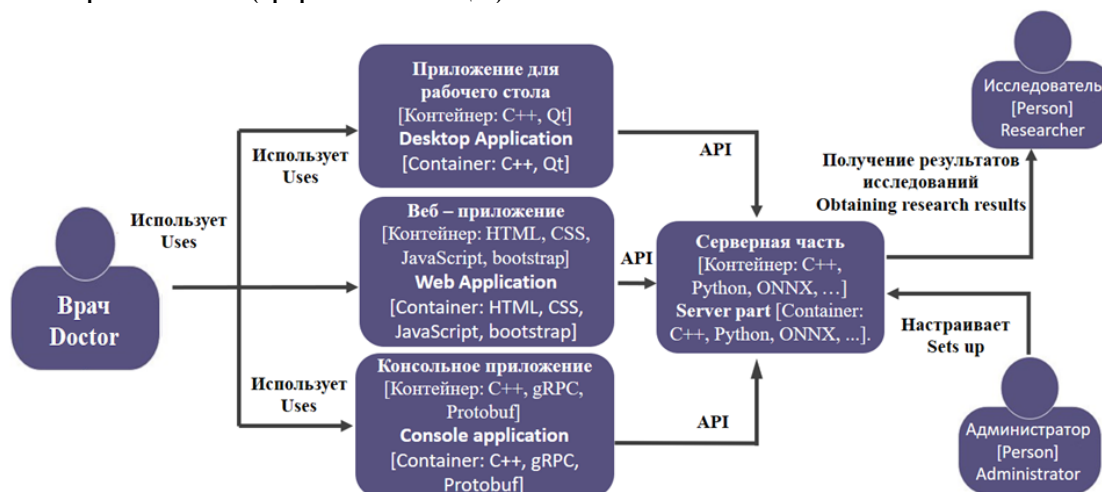
Klimanov Igor A., N.N. Blokhin National Medical Research Center of Oncology, Ministry of Health of the Russian Federation, Russian Federation, 24 Kashirskoye shosse, Moscow, 115522, Russian Federation,

Cand. Sci. (Medicine), Head of Centralized Scientific and Clinical Laboratory Department, ORCID: 0000-0001-8593-1098, e-mail: Igorklimanov@yandex.ru

Despite attempts to automate microscopic analysis, it is still predominantly performed manually, which requires high physician expertise and can lead to errors, low work speed, and insufficient accuracy. Therefore, the development of new software tools for analyzing images of nucleated cells remains a relevant task. The work presents the development of a software system for analyzing the results of a deep learning model, aimed at automating the annotation of nucleated cells obtained from bone marrow smear images using an automated biomedical image analyzer. The system includes tools for data labeling, analysis of model training quality, and inference, ensuring cross-platform compatibility and independence from specific machine learning frameworks. The software is implemented using the C++ language, the Qt framework, the OpenCV library, and the ONNX Runtime. Experimental studies conducted as part of the work showed high consistency indicators for the trained model, with a Kappa coefficient ranging from 71 to 94 %. The results of analyzing images of hematopoietic bone marrow cells showed an accuracy of 92 % when compared to expert data. The developed system allows minimizing the workload on specialists by providing preliminary data labeling and simplifying the process of verification and correction. The results of the work can be used not only for data labeling and model quality analysis, but also for detecting objects of other types.

Keywords: computer vision, deep learning, computer microscopy, data markup, images of nucleated cells

Graphical annotation (Графическая аннотация)



ВВЕДЕНИЕ

Одним из массовых видов исследований при диагностике онкогематологических заболеваний является микроскопический анализ препаратов крови и аспиратов костного мозга. Попытки автоматизации микроскопического анализа предпринимались с момента изобретения микроскопа. До сих пор данный вид анализа проводится в основном вручную, с участием опытного врача и высоким уровнем квалификации [1–3]. Благодаря развитию компьютерных технологий и достижениям в области машинного обучения в последние годы стало возможным создание как частично автоматизированных, так и полностью автоматизированных комплексов микроскопии [4–6].

Несмотря на доступность различных решений на рынке, проблема разработки новых программных инструментов для анализа изображений ядродержащих клеток на препаратах периферической крови и аспиратах костного мозга остается актуальной из-за возможных ошибок, низкой скорости работы, недостаточной точности, а также отсутствия программных и технических решений для анализа препаратов костного мозга [7–9].

Одной из возникающих задач в процессе обучения модели с учителем – задача разметки данных для обучения модели.

Цель работы – разработка программной системы для анализа результатов модели глубокого обучения на примере изображений ядродержащих клеток с препаратов костного мозга, которая упрощает разметку и корректировку данных опытным специалистом.

МАТЕРИАЛЫ И МЕТОДЫ

В работе для тестирования разработанных программных инструментов применялась референсная база данных изображений ядросодержащих клеток [10]. Разработанное программное решение состоит из трёх модулей: первый – для разметки данных; второй обеспечивает анализ результатов обучения модели и третий – инференса, для запуска нейронной сети, представленной в формате ONNX.

При разработке данных модулей применялся язык программирования C++, фреймворк Qt, библиотека OpenCV и инструментарий ONNX Runtime [11]. В качестве системы сборки использовался CMake.

Выбор инструментов продиктован следующими соображениями. Язык C++ и фреймворк Qt образуют связку в целях кроссплатформенной разработки графического интерфейса пользователя для самых распространённых операционных систем – Windows, Linux и MacOS. OpenCV и ONNX Runtime были выбраны как кроссплатформенные инструменты обработки входных изображений и запуска моделей в формате *onnx*. Формат *onnx* выбран как независимый формат моделей нейронных сетей, не зависящий от фреймворка машинного обучения.

Датасет для обучения имеет собственный формат:

- директория `images` – хранит изображения, каждое из которых использует в качестве имени GUID;
- директория `images_labels` – содержит текстовые файлы в формате `txt`, в каждой строке которого содержится описание каждого прямоугольника. Имя каждого файла совпадает с именем соответствующего изображения;
- файл `predefined_classes.txt` – для хранения имен предопределённых классов, используемых при обучении и аннотировании данных.

ПРЕДЛАГАЕМОЕ РЕШЕНИЕ

Каждый модуль представляет из себя отдельный CMake проект.

Модуль разметки данных – отдельное приложение с графическим интерфейсом пользователя, которое позволяет просматривать результаты разметки, сделанные как экспертом, так и моделью, а также вносить изменения и уточнять существующую разметку.

Интерфейс приложения представлен на рисунке 1.




Рисунок 1 – Интерфейс программной системы анализа результатов модели глубокого обучения на примере изображений ядросодержащих клеток с препаратов костного мозга

Основные функции включают:

- загрузку и отображение биомедицинских изображений форматов JPG, PNG, BMP;
- создание, редактирование и сохранение аннотаций к изображениям;
- применение инструментов для выделения областей интереса на изображениях;
- сохранение аннотированных данных для использования в других медицинских и исследовательских приложениях.

Интерфейс для загрузки изображений:

- Структура входных данных:
data
images
{c4c6776d-a6f8-4ce9-8046-a1a4d0fd1936}.jpg
...
{c6eeb825-0bfb-4076-89e4-53d5aac00340}.jpg
labels
{c4c6776d-a6f8-4ce9-8046-a1a4d0fd1936}.txt
...
{c6eeb825-0bfb-4076-89e4-53d5aac00340}.txt

- Возможность пакетной загрузки изображений.

Инструменты аннотации:

- набор инструментов для рисования (прямоугольник) для выделения областей на изображениях;
- функции для добавления/удаления/редактирования аннотаций;
- возможность сохранения и экспорта аннотаций в текстовом виде.

Анализ и классификация:

- функции для ручной коррекции и подтверждения результатов автоматического анализа.

Модуль анализа качества обучения модели также представляет собой отдельное приложение, способное выводить результаты предсказания нейронной сети и эксперта. Интерфейс приложения представлен на рисунке 2.

	Lymphocyte (0)	Metamyelocyte (1)	Monocyte (2)	Myelocyte (3)	Normoblasts (4)	Rod neutrophil (5)	Segmentonuclear neutrophil (6)	blast (7)	Promyelocyte (8)	Eosinophil (9)	Basophil (10)	Magakarocyte
{0ca8d788-f031-45ed-8302-a2a6135d7f53}	2/2	3/2	1/1	1/1	4/2	1/1	2/2	17/21		1/0		
{0cd9a857-ad75-4771-ad9b-1a927a9f6f56}_2				1/1	1/1	3/3	3/3	14/14		2/2		
{355af27c-bc18-4af5-8f4b-9fe04907d1c}				1/1	1/1		2/2	17/17		1/1		
{50a69aa9-8be5-4b28-9b0d-dc55e71e2947}	4/4	2/2					2/2	15/15				
{55baa204-1c32-49fd-b962-137e4650503}	3/3				1/1		2/2	11/11				
{71bf60a5-025d-43e4-9be0-36dfbb47f6c}				1/1			3/3	21/21				
{a8ca19e9-b1aa-40b8-85fd-7af85537b797}		1/1	1/1				1/1					
{c065c731-011c-4900-8522-071b96eedc90}						1/1	1/1					
{c09c51b3-ddd7-46e2-b3c6-3893ba2cc84}		1/1		1/1		1/1	2/2			2/2		
{c1423ae7-9405-47d2-a091-da1712b84d35}						1/1	2/2					
{c219a92e-ea88-4dda-9a65-28a3508a9a95}		1/1	1/1	1/1		1/1	6/6	2/2		1/1		
{c3346ea7-5372-46ae-bfb2-4eace065af19}	1/1			1/1			2/2					
{c36b56fd-653f-45c9-8115-3524ab4f984c}	2/2			1/1	4/4		5/5	1/1		1/1		
{c4c6776d-a6f8-4ce9-8046-a1a4d0fd1936}	1/1			1/1			2/2					
{c565d373-2d56-472d-b56b-115f8edc1c04}	1/1	1/1										
{c6eeb825-0bfb-4076-89e4-53d5aac00340}	1/1	1/1			1/2	3/2	8/8	1/2		1/0		
{c8f8383-5205-4db2-8bae-83fbc3d0729}	1/1			2/2			6/6	2/2				
{c9d3bfb1-d8b7-40aa-896e-215021f8c2da}		1/1	1/1	2/2			4/4			1/1		
{ca235379-b913-4c4a-8376-08ddcb7c2996}		1/1					5/5	2/2		1/1		
{cbb39f5-9a1c-4a7e-ab2d-195812111e7f}	2/2		1/1		1/1	3/3	7/7					
{cc518fe3-467c-491a-abda-983a5c94fc2a}	1/1	3/3		2/2	2/2	1/1	12/12	3/3		1/1		
{cc739e13-706e-472b-ae23-4aae09eaabd0}		1/1					2/2	3/3				
{cceb5665-7edf-4d39-457e-b429db20f5b0}	2/2					3/3	2/2			1/1		
{cdf19898-3331-4c8b-94aa-26d8f52fabbb}	1/1	3/3	1/1	1/1	2/2		10/10	2/2				
{cd4ab13c-dc7b-48af-8b44-5219035505f2}	1/1	2/2			1/1	1/1	11/11	2/2				
{cd92b963-dd22-481d-a5cc-8fbc9937b6fd}		1/1										
{ce4653a8-fac2-460e-89e5-1cb5b35c46d3}				1/1			1/1					
{cf210c0a-4b35-4fa6-abcf-41ad1ea3a000}	1/1				1/1			5/5	6/6			
{cf23dfb7-15f6-4fb1-bfcd-57a2abf19258}								6/6				
{cf4c49b0-1f68-45fa-9b7b-77445116a6f}	1/1							1/1				

Рисунок 2 – Интерфейс программной системы оценки качества обучения модели глубокого обучения на примере изображений ядросодержащих клеток с препаратов костного мозга

Анализ качества обучения модели глубокого обучения на основе изображений ядросодержащих клеток из препаратов костного мозга является критически важным для обеспечения высокой точности и надежности результатов. После завершения обучения нейронной сети необходимо объективно оценить полученные результаты и сопоставить их с эталонными данными, чтобы удостовериться в корректности работы модели. Учитывая регулярный и циклический характер этого процесса, разработка специализированного программного обеспечения становится особенно актуальной. Данная система предоставляет следующие преимущества:

Объективность оценки. Программная система обеспечивает автоматическую и объективную оценку качества обучения модели, исключая влияние субъективных факторов и возможных ошибок, которые могут возникнуть при ручной оценке.

Сопоставление данных. Система позволяет эффективно сопоставлять данные, полученные в результате обучения, с эталонными данными, что способствует выявлению отклонений и улучшению модели.

Регулярность и цикличность. Благодаря регулярному и циклическому характеру процесса обучения и оценки модели, программная система автоматизирует эти этапы, что значительно сокращает временные и ресурсные затраты.

Улучшение модели. Оценка качества обучения помогает выявить слабые места в модели и внести необходимые корректировки, что ведет к повышению точности и надежности результатов.

ЭКСПЕРИМЕНТ

Для проведения экспериментального исследования используется архитектура системы, включающая веб-приложение, консольное приложение и серверную часть. Врач и исследователь взаимодействуют с системой через веб-приложение и консольное приложение соответственно. Эти приложения обмениваются данными с серверной частью через API (Application Programming Interface), обеспечивающей взаимодействие между программными компонентами. Серверная часть обрабатывает запросы и предоставляет результаты исследований пользователю и администратору. В качестве модели для эксперимента была выбрана YOLOv8 и обучена на датасете, размеченном экспертами. Для верификации разработанного программного решения был взят размеченный набор из 100 изображений. Исходная выборка данных до процедуры аугментации была сформирована на основании анализа 2390 изображений и включала следующие типы клеток костного мозга: бластов насчитывалось 12 535, промиелоцитов – 4, миелоцитов – 292, метамиелоцитов – 200, палочкоядерных нейтрофилов – 243, сегментоядерных нейтрофилов – 653, эозинофилов – 86, базофилов – 6, моноцитов – 285, лимфоцитов – 1 118, плазматических клеток – 8. Среди нормобластов было выделено три группы: базофильные – 33, полихроматофильные – 105, оксифильные – 493, общее число нормобластов составило 20. Эритробластов зафиксировано 11, мегакариоцитов – 2, макрофагов – 1. Дополнительно были учтены такие элементы, как клетки, признанные непригодными для анализа (1 065), митозы (39), артефакты (25) и тени Гумпрехта (1 929) [10]. Результаты предсказания модели на верификационной выборке в сравнении с данными, установленными экспертом представлены в таблице.

Таблица – Результат анализа модели глубокого обучения изображений ядродержащих клеток и сравнение с данными установленными экспертом

Тип распознаваемого объекта	Референсное значение	Значение, предсказанное моделью
Бласт	5	67
Миелоцит	45	40
Метамиелоцит	36	30
Палочкоядерный нейтрофил	59	36
Сегментоядерный нейтрофил	303	362
Моноцит	6	7
Лимфоцит	48	46
Нормобласты	32	36

Из таблицы видно, что результаты работы нейронной сети и эксперта в основном совпадают. Расхождения выявлены в установлении типа – бласт. Данное расхождение может быть связано с несбалансированностью выборки или объектах, которые не были размечены и присутствовали при обучении. При этом разработанная программная система показала свою эффективность работы в части снижения нагрузки на эксперта при разметке данных. Это обеспечивается за счет предварительной разметки данных, и эксперту останется только проверить корректность разметки выполненной обученной моделью.

Веб-приложение, в котором проводился анализ результатов исследования, представлено на рисунке 3.

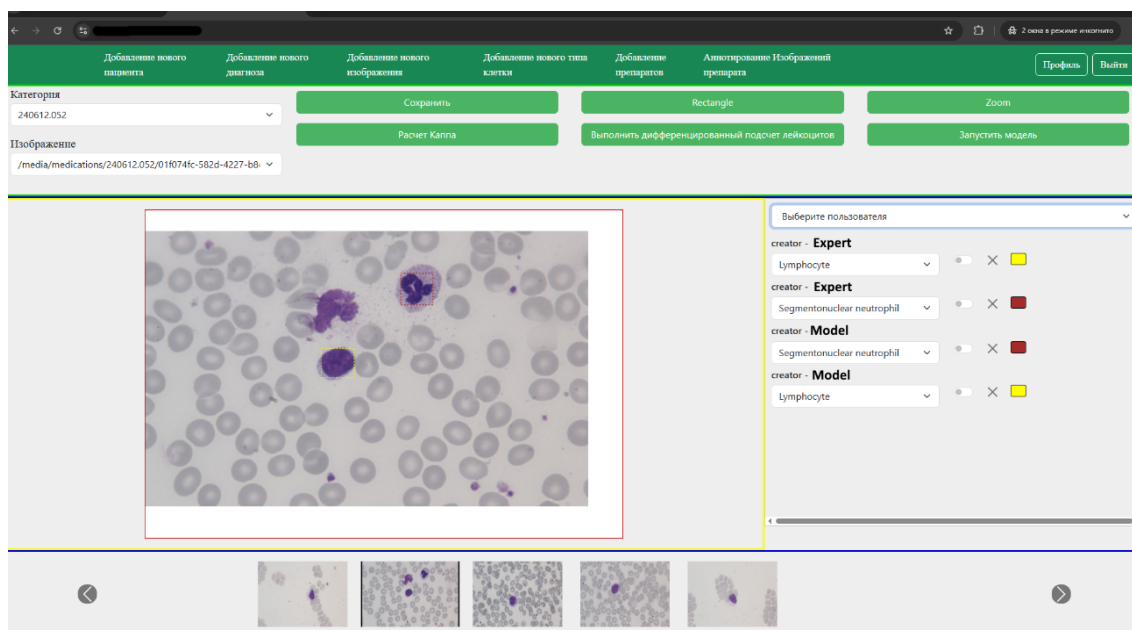


Рисунок 3 – Интерфейс веб-приложения формирования диагностического заключения с применением нейронных сетей глубокого обучения и модулем анализа результатов исследования

Проведен анализ обученной модели на 20 препаратах, которые не использовались в процессе обучения, тестирования и валидации. В качестве критерия качества был выбран коэффициент Каппа. Исследование продемонстрировало потенциал нейронных сетей для выполнения дифференцированного подсчета гемопоэтических клеток с изображений препаратов костного мозга. Обученная модель показала высокую эффективность в обнаружении объектов и объединении перекрывающихся рамок, что является ключевым для точной классификации клеток. Однако для повышения точности необходимо учитывать такие факторы, как размер и структура клеток, чтобы минимизировать ошибки классификации и увеличить представительность классов. Данные обученной модели подтверждены высокими показателями согласованности – коэффициент Каппа составил от 71 до 94 %.

Кроме того, выполнен дифференцированный подсчет кровяных клеток с применением программного обеспечения. Проведен анализ результатов подсчета в программе, сравнение полученного результата с миелограммой, а также контроль результатов подсчета другими экспертами. Точность анализа подсчета, выполненного экспертом и обученной моделью, составила 92 %.

ЗАКЛЮЧЕНИЕ

В работе представлена программная система анализа результатов работы модели глубокого обучения на примере изображений ядросодержащих клеток с препаратов костного мозга.

Система обеспечивает разметку изображений ядросодержащих клеток, запуск обученной модели нейронной сети, анализ полученных результатов, а также предоставляет возможность корректировки результатов экспертом. Данные обученной модели подтверждены высокими показателями согласованности – коэффициент Каппа составил от 71 до 94 %. Точность дифференцированного подсчета гемопоэтических клеток, выполненного экспертом и обученной моделью, составила 92 %.

Полученные результаты могут быть использованы при разметке данных и анализе качества моделей. Применение описанных решений не ограничивается задачей обнаружения гемопоэтических клеток; программная система может использоваться также для задач обнаружения объектов других типов.

В будущем возможно включение разработанных программных инструментов в состав программного комплекса для автоматизации компьютерной микроскопии.

Список источников

1. Kreiss, L. Digital staining in optical microscopy using deep learning-a review / L. Kreiss, S. Jiang, X. Li, S. Xu, K. Zhou, K. Lee, A. Muhlberg, K. Kim, A. Chaware, M. Ando, L. Barisoni, Ah L. Seung, G. Zheng, K. Lafata, O. Friedrich, and R. Horstmeyer // *PhotonIX*. – 2023. – Vol. 4. – P. 1–32.
2. Fanous, M. J. Digital staining facilitates biomedical microscopy / M. J. Fanous, N. Pillar, A. Ozcan // *Frontiers in Bioinformatics*. – 2023. – Vol. 3.
3. Yadav, D. Morphological diagnosis of hematologic malignancy using feature fusion-based deep convolutional neural network / D. Yadav, D. Kumar, A. Jalal, A. Kumar, K. Singh, and M. A. Shah // *Scientific Reports*. – 2023. – Vol. 13.

4. Lv, Z. High-accuracy morphological identification of bone marrow cells using deep learning-based morpho system / Z. Lv, X. Cao, X. Jin, S. Xu, H. Deng // *Scientific Reports*. – 2023. – Vol. 13.
5. Barrera, K. Automatic normalized digital color staining in the recognition of abnormal blood cells using generative adversarial networks / K. Barrera, J. Rodellar, S. Alferez, and A. Merino // *Computer Methods and Programs in Biomedicine*. – 2023. – Vol. 240. – P. 107629.
6. Bukhari, M. A deep learning framework for leukemia cancer detection in microscopic blood samples using squeeze and excitation learning / M. Bukhari, S. Yasmin, S. Sammad, and A. A. El-Latif // *Mathematical Problems in Engineering*. – 2022. – Vol. 2022. – P. 1–18
7. Fazeli, S. Beyond Labels: Visual Representations for Bone Marrow Cell Morphology Recognition / S. Fazeli, A. Samiei, T. D. Lee, M. Sarrafzadeh // *ArXiv*. – 2022. – Vol. abs/2205.09880. – P. 111–117.
8. Medovy, V. S. An Adaptable Cloud-Based Multiple-Unit Laboratory Microscopy System / V. S. Medovy, G. D. Volkov, N. M. Strela, I. V. Pervushkin // *Biomedical Engineering*. – 2021. – Vol. 55. – P. 36–40. DOI 10.1007/s10527-021-10066-2.
9. Дмитриева, В. В. Медицинская информационная система с применением web-технологий для диагностики острых лимфобластных лейкозов и минимальной остаточной болезни / В. В. Дмитриева, Н. Н. Тупицын, Е. В. Поляков, Е. М. Носова, А. Д. Палладина, В. И. Цыпляк, К. А. Либерис // *Безопасность информационных технологий*. – 2021. – № 28 (3). – С. 44–55. <https://doi.org/10.26583/bit.2021.3.03>.
10. Поляков, Е. В. Правообладатель федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский ядерный университет «МИФИ» (НИЯУ МИФИ). База данных клеток костного мозга больных острым лимфобластным лейкозом : заявка № 2023620945: заявл. 06.04.2023 : опубл. 20.04.2023. Свидетельство о государственной регистрации базы данных № 2023621283 Российская Федерация / Е. В. Поляков, Н. Н. Тупицын, И. Н. Серебрякова А. Д. Палладина.
11. Park, S. Conversion Tools of Spiking Deep Neural Network based on ONNX / S. Park, J. Heo // *The journal of the Institute of Internet, Broadcasting and Communication*. – 2020. – Vol. 20. – P. 165–170.

References

1. Kreiss, L., Jiang, S., Li, X., Xu, S., Zhou, K., Lee, K., Muhlberg, A., Kim, K., Chaware, A., Ando, M., Barisoni, L., Seung, Ah L., Zheng, G., Lafata, K., Friedrich, O., Horstmeyer, R. Digital staining in optical microscopy using deep learning – a review. *PhotonIX*, 2023, vol. 4, pp. 1–32. DOI 10.1186/s43074-023-00113-4.
2. Fanous, M. J., Pillar, N., Ozcan, A. Digital staining facilitates biomedical microscopy. *Frontiers in Bioinformatics*, 2023, vol. 3.
3. Yadav, D., Kumar, D., Jalal, A., Kumar, A., Singh, K., Shah, M. A. Morphological diagnosis of hematologic malignancy using feature fusion-based deep convolutional neural network. *Scientific Reports*, 2023, vol. 13.
4. Lv, Z., Cao, X., Jin, X., Xu S., Deng H. High-accuracy morphological identification of bone marrow cells using deep learning-based Morphogo system. *Scientific Reports*, 2023, vol. 13.
5. Barrera, K., Rodellar, J., Alferez, S., Merino, A. Automatic normalized digital color staining in the recognition of abnormal blood cells using generative adversarial networks. *Computer Methods and Programs in Biomedicine*, 2023, vol. 240, p. 107629.
6. Bukhari, M., Yasmin, S., Sammad, S., El-Latif, A. A. A deep learning framework for leukemia cancer detection in microscopic blood samples using squeeze and excitation learning. *Mathematical Problems in Engineering*, 2022, vol. 2022, pp. 1–18.
7. Fazeli, S., Samiei, A., Lee, T. D., Sarrafzadeh, M. Beyond labels: visual representations for bone marrow cell morphology recognition. *ArXiv*, 2022, vol. abs/2205.09880, pp. 111–117.
8. Medovy V. S., Volkov G. D., Strela N. M., Pervushkin I. V. An adaptable cloud-based multiple-unit laboratory microscopy system. *Biomedical Engineering*, 2021, vol. 55, pp. 36–40. DOI 10.1007/s10527-021-10066-2.
9. Dmitrieva, V. V., Tupitsyn, N. N., Polyakov, E. V., Nosova, E. M., Paladdina, A. D., Tsypliyak, V. I., Liberis, K. A. et al. Medical information system based on web technologies for the diagnosis of acute lymphoblastic leukemia and minimal residual disease. *IT Security*, 2021, vol. 28 (3), pp. 44–55. doi:10.26583/bit.2021.3.03. (In Russ.).
10. Polyakov, E. V. Tupitsyn, N. N., Serebryakova, I. N., Palladina, A. D. *Copyright holder: Federal State Autonomous Educational Institution of Higher Education “National Research Nuclear University MEPhI” (NRNU MEPhI). Database of bone marrow cells from patients with acute lymphoblastic leukemia* : application no. 2023620945: declared 06.04.2023 : published 20.04.2023. Certificate of state registration of the database no. 2023621283 Russian Federation (In Russ.).
11. Park, S., Heo, J. Conversion tools of spiking deep neural network based on ONNX. *The Journal of the Institute of Internet Broadcasting and Communication*, 2020, vol. 20, pp. 165–170.

Статья поступила в редакцию 06.05.2025; одобрена после рецензирования 14.07.2025; принята к публикации 15.07.2025.

The article was submitted 06.05.2025; approved after reviewing 14.07.2025; accepted for publication 15.07.2025.

ПРИБОРОСТРОЕНИЕ, МЕТРОЛОГИЯ И ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ ПРИБОРЫ И СИСТЕМЫ

ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ И УПРАВЛЯЮЩИЕ СИСТЕМЫ

УДК 681.518.3

ИСПОЛЬЗОВАНИЕ БАЙЕСОВСКОГО ПОДХОДА К ОБРАБОТКЕ ДАННЫХ И ПРИНЯТИЮ РЕШЕНИЙ В ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫХ СИСТЕМАХ ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ В УСЛОВИЯХ НЕОПРЕДЕЛЕННОСТИ И НЕПОЛНОТЫ ИНФОРМАЦИИ

Звягин Леонид Сергеевич, Финансовый университет при Правительстве Российской Федерации, 125167, Москва, пр-кт Ленинградский, 49/2,
кандидат экономических наук, доцент, ORCID: 0000-0003-4983-6012, e-mail: lszvyagin@fa.ru

Современные информационно-измерительные системы сталкиваются с возрастающей сложностью задач обработки данных в условиях значительной неопределенности входных параметров и неполноты измерительной информации. Байесовский подход представляет математически обоснованную парадигму для количественной оценки и управления неопределенностью через последовательное обновление вероятностных моделей на основе поступающих измерительных данных. Целью исследования является разработка комплексной методологии применения байесовских методов в информационно-измерительных системах для повышения точности оценки состояния контролируемых объектов и надежности принимаемых решений. Экспериментальная верификация проводилась на базе многоканальной измерительной системы мониторинга промышленного оборудования, включающей 156 измерительных каналов различной физической природы с непрерывным сбором данных в течение 8 месяцев 2024 г. Результаты показали повышение точности измерений на 18,3 % при снижении среднеквадратичной ошибки прогнозирования на 24,7 % по сравнению с традиционными детерминистическими методами. Байесовская калибровка сенсорных систем обеспечила сокращение времени адаптации к изменяющимся условиям эксплуатации с 45 до 12 секунд при одновременном снижении ложных срабатываний системы диагностики на 42 %. Практическая значимость работы заключается в создании теоретической основы для проектирования адаптивных информационно-измерительных систем нового поколения, способных функционировать в условиях многофакторной неопределенности с количественной оценкой достоверности результатов измерений.

Ключевые слова: байесовский вывод, информационно-измерительные системы, калибровка сенсоров, неопределенность измерений, адаптивные алгоритмы, принятие решений

USING A BAYESIAN APPROACH TO DATA PROCESSING AND DECISION-MAKING IN INFORMATION AND MEASUREMENT SYSTEMS TO IMPROVE ACCURACY IN CONDITIONS OF UNCERTAINTY AND INCOMPLETENESS OF INFORMATION

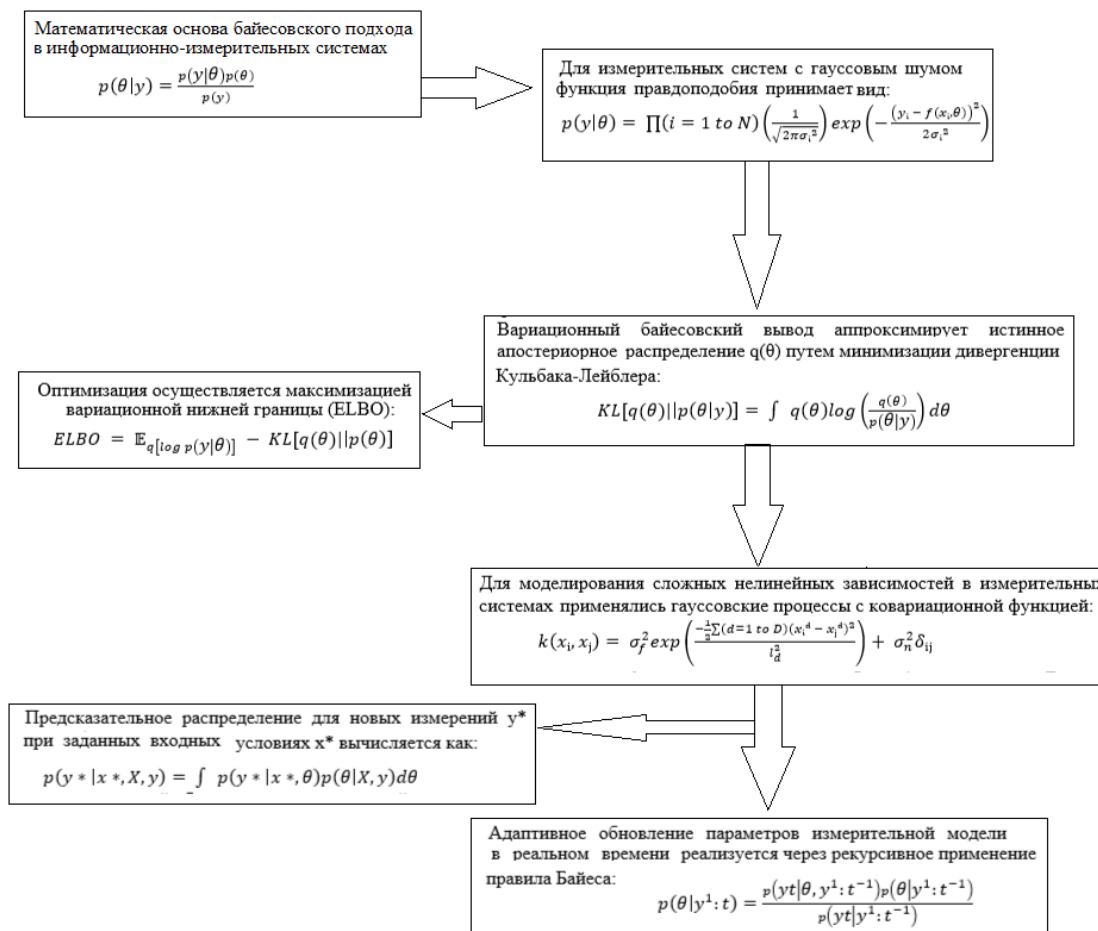
Leonid S. Zvyagin, Financial University under the Government of the Russian Federation, 49/2 Leningradsky Ave., Moscow, 125167, Russian Federation

Cand. Sci. (Economics), Associate Professor, ORCID: 0000-0003-4983-6012, e-mail: lszvyagin@fa.ru

Modern information and measurement systems face an increasing complexity of data processing tasks in conditions of significant uncertainty of input parameters and incompleteness of measurement information. The Bayesian approach provides a mathematically sound paradigm for quantifying and managing uncertainty through consistent updating of probabilistic models based on incoming measurement data. The aim of the research is to develop a comprehensive methodology for applying Bayesian methods in information and measurement systems to improve the accuracy of assessing the condition of controlled objects and the reliability of decisions. The experimental verification was carried out on the basis of a multichannel measuring system for monitoring industrial equipment, which includes 156 measuring channels of various physical nature with continuous data collection for 8 months in 2024. The results showed an increase in measurement accuracy by 18,3 % while reducing the standard error of forecasting by 24,7 % compared with traditional deterministic methods. Bayesian calibration of sensor systems has reduced the adaptation time to changing operating conditions from 45 to 12 seconds, while reducing false alarms of the diagnostic system by 42 %. The practical significance of the work lies in the creation of a theoretical basis for the design of adaptive information and measurement systems of a new generation capable of operating in conditions of multifactorial uncertainty with a quantitative assessment of the reliability of measurement results.

Keywords: bayesian inference, information and measurement systems, sensor calibration, measurement uncertainty, adaptive algorithms, decision-making.

Graphical annotation (Графическая аннотация)



ВВЕДЕНИЕ

Развитие современных информационно-измерительных систем характеризуется переходом к решению многомерных задач обработки данных в условиях значительной априорной неопределенности параметров контролируемых процессов и ограниченности доступной измерительной информации [1]. Фундаментальные исследования последних лет демонстрируют критическую важность разработки методов, способных обеспечить эффективную интеграцию информации из разнородных источников при наличии статистических и эпистемических неопределенностей [2]. Байесовский подход к анализу данных предоставляет математически строгую основу для решения подобных задач, поскольку позволяет формализовать процедуры обновления знаний о состоянии системы по мере поступления новых измерительных данных и обеспечивает количественную оценку достоверности принимаемых решений [3]. Теоретические основы байесовского вывода находят все более широкое применение в области разработки интеллектуальных информационно-измерительных систем, где требуется обеспечение высокой точности измерений при минимизации влияния случайных и систематических погрешностей. Ключевыми преимуществами байесовских методов является возможность инкорпорирования априорных знаний о физических процессах в алгоритмы обработки данных, адаптивного управления параметрами измерительных каналов в реальном времени и получения вероятностных оценок неопределенности результатов измерений. Современные исследования в области машинного обучения для задач количественной оценки неопределенности подтверждают эффективность байесовских методов при решении сложных инженерных задач, включая прямые и обратные задачи анализа неопределенности, диагностику отказов и оценку устойчивости системы [4]. Практические применения байесовской калибровки сенсорных систем демонстрируют существенные преимущества в точности и надежности измерений по сравнению с традиционными подходами [5].

Анализ терминологического аппарата выявляет существенные различия в интерпретации понятий алеаторической и эпистемической неопределенности в контексте информационно-измерительных систем. Алеаторическая неопределенность традиционно ассоциируется с внутренней стохастичностью измеряемых процессов и может быть количественно охарактеризована средствами

классической теории вероятностей, тогда как эпистемическая неопределенность отражает ограниченность знаний о параметрах математических моделей системы [6]. В рамках данного исследования под байесовским подходом понимается совокупность математических методов, основанных на теореме Байеса и позволяющих осуществлять последовательное обновление вероятностных распределений параметров системы по мере поступления новых наблюдений. Информационно-измерительная система рассматривается как совокупность технических средств, алгоритмического обеспечения и методических процедур, предназначенных для автоматизированного получения, обработки, передачи и представления измерительной информации о состоянии контролируемых объектов или процессов.

Систематический анализ современной научной литературы позволяет выделить несколько ключевых нерешенных проблем в области применения байесовских методов в информационно-измерительных системах. Первая проблема связана с отсутствием универсальных подходов к формированию априорных распределений для параметров измерительных моделей в условиях ограниченной информации о физических процессах [7]. Вторая проблема касается вычислительной сложности байесовского вывода для высокоразмерных задач, характерных для современных распределенных измерительных систем [8]. Третья проблема заключается в недостаточной проработке методов валидации байесовских моделей в контексте специфических требований метрологического обеспечения измерительных процедур [9]. Четвертая проблема связана с необходимостью разработки адаптивных алгоритмов, способных автоматически корректировать параметры байесовских моделей при изменении условий эксплуатации измерительной системы.

Уникальность предлагаемого подхода заключается в интеграции современных достижений теории байесовского вывода с метрологическими принципами обеспечения точности измерений и разработке комплексной методологии применения вероятностных методов для повышения эффективности информационно-измерительных систем в условиях многофакторной неопределенности. Научная новизна исследования определяется разработкой теоретических основ адаптивной байесовской калибровки параметров информационно-измерительных систем и созданием алгоритмических решений для реализации динамического обновления вероятностных моделей измерительных процессов в реальном времени.

МЕТОДЫ

Методологическая основа исследования базируется на интеграции классических принципов теории байесовского вывода с современными подходами к анализу неопределенности в технических системах. Выбор байесовского подхода обусловлен его способностью обеспечивать математически корректное обновление знаний о состоянии измерительной системы при поступлении новых данных, что критически важно для задач реального времени в информационно-измерительных системах [10]. Вариационный байесовский вывод применялся для аппроксимации апостериорных распределений параметров в случаях высокой размерности пространства состояний, что обеспечивает вычислительную эффективность алгоритмов [11]. Методы активного обучения использовались для оптимизации процедур сбора измерительной информации с целью максимизации информационной ценности каждого нового наблюдения. Гауссовские процессы применялись в качестве непараметрических априорных распределений для моделирования сложных нелинейных зависимостей между измеряемыми величинами и параметрами состояния контролируемых объектов.

Экспериментальное исследование проводилось на базе информационно-измерительной системы мониторинга состояния промышленного оборудования химического производства, включающей 156 измерительных каналов различной физической природы: термометрические (62 канала), манометрические (38 каналов), расходометрические (31 канал), аналитические (25 каналов). Сбор данных осуществлялся в период с апреля по ноябрь 2024 г. с частотой дискретизации 0,1 Гц для медленно изменяющихся процессов и 10 Гц для динамических параметров. Общий объем обработанных данных составил 1,87 терабайта измерительной информации. Калибровка измерительных каналов проводилась согласно требованиям ГОСТ 8.568-2017 с использованием эталонных средств измерений класса точности 0,1. Критерии включения данных в выборку: стабильность функционирования измерительного оборудования, отсутствие внештатных режимов работы технологического процесса, полнота записи данных не менее 97% от планового времени наблюдений.

Статистический анализ включал оценку стационарности временных рядов с использованием расширенного теста Дики-Фуллера, анализ кросс-корреляционных связей между измерительными каналами, идентификацию периодических компонент методом спектрального анализа. Байесовская калибровка модели осуществлялась с применением вариационного подхода с автоматической дифференциацией. Гиперпараметры априорных распределений определялись методом максимального правдоподобия с последующей валидацией на независимой тестовой выборке объемом 25 % от общего массива данных. Качество байесовских моделей оценивалось с использованием информационного критерия

WAIC (Widely Applicable Information Criterion) и показателей предсказательной способности. Вычислительная реализация алгоритмов выполнялась в среде Python 3.11 с использованием библиотек PyMC 5.0 для байесовского вывода и TensorFlow Probability для вариационной оптимизации.

Математическая основа байесовского подхода в информационно-измерительных системах базируется на теореме Байеса, которая позволяет обновлять знания о параметрах системы θ при поступлении новых измерительных данных y :

$$p(\theta|y) = \frac{p(y|\theta)p(\theta)}{p(y)}, \quad (1)$$

где $p(\theta|y)$ – апостериорное распределение параметров после получения данных;

$p(y|\theta)$ – функция правдоподобия, описывающая вероятность наблюдения данных y при заданных параметрах θ ;

$p(\theta)$ – априорное распределение параметров, отражающее предварительные знания о системе;

$p(y)$ – маргинальная вероятность данных (нормализующая константа).

Для измерительных систем с гауссовым шумом функция правдоподобия принимает вид:

$$p(y|\theta) = \prod_{i=1}^N \left(\frac{1}{\sqrt{2\pi\sigma_i^2}} \right) \exp \left(-\frac{(y_i - f(x_i, \theta))^2}{2\sigma_i^2} \right) \quad (2)$$

где N – количество измерений;

y_i – i -е измеренное значение;

$f(x_i, \theta)$ – модель измерительного процесса;

x_i – входные условия i -го измерения;

σ_i^2 – дисперсия шума i -го измерения.

Вариационный байесовский вывод аппроксимирует истинное апостериорное распределение $q(\theta)$ путем минимизации дивергенции Кульбака-Лейблера:

$$KL[q(\theta)||p(\theta|y)] = \int q(\theta) \log \left(\frac{q(\theta)}{p(\theta|y)} \right) d\theta, \quad (3)$$

где $KL[\cdot||\cdot]$ – дивергенция Кульбака-Лейблера;

$q(\theta)$ – вариационная аппроксимация апостериорного распределения.

Оптимизация осуществляется максимизацией вариационной нижней границы (ELBO):

$$ELBO = \mathbb{E}_{q[\log p(y|\theta)]} - KL[q(\theta)||p(\theta)], \quad (4)$$

где $\mathbb{E}_{q[\cdot]}$ – математическое ожидание относительно распределения $q(\theta)$.

Для моделирования сложных нелинейных зависимостей в измерительных системах применялись гауссовские процессы с ковариационной функцией:

$$k(x_i, x_j) = \sigma_f^2 \exp \left(\frac{-\frac{1}{2} \sum_{d=1}^D (x_i^d - x_j^d)^2}{l_d^2} \right) + \sigma_n^2 \delta_{ij}, \quad (5)$$

где σ_f^2 – дисперсия сигнала;

l_d – характерный масштаб по d -й координате;

D – размерность входного пространства;

σ_n^2 – дисперсия шума;

δ_{ij} – символ Кронекера.

Предсказательное распределение для новых измерений y^* при заданных входных условиях x^* вычисляется как:

$$p(y^* | x^*, X, y) = \int p(y^* | x^*, \theta) p(\theta | X, y) d\theta, \quad (6)$$

где X – матрица входных условий обучающих данных; данный интеграл обеспечивает учет неопределенности в параметрах модели при формировании прогнозов.

Адаптивное обновление параметров измерительной модели в реальном времени реализуется через рекурсивное применение правила Байеса:

$$p(\theta | y^1:t) = \frac{p(y^t | \theta, y^1:t^{-1}) p(\theta | y^1:t^{-1})}{p(y^t | y^1:t^{-1})}, \quad (7)$$

где $y^1:t$ – последовательность измерений от момента 1 до t ; данная формула позволяет последовательно обновлять знания о параметрах системы по мере поступления новых измерительных данных без необходимости пересчета всей истории наблюдений.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Комплексный анализ эффективности байесовского подхода в информационно-измерительных системах продемонстрировал значительные преимущества по сравнению с традиционными методами обработки данных в условиях неопределенности. Результаты экспериментального исследования свидетельствуют о качественном повышении точности оценки состояния контролируемых объектов при использовании адаптивных байесовских алгоритмов. Анализ данных 156 измерительных каналов выявил существенную неоднородность распределения погрешностей измерений в зависимости от типа сенсорного оборудования и условий эксплуатации. Статистическая обработка результатов

показала статистически значимое улучшение основных метрологических характеристик информационно-измерительной системы при внедрении байесовских методов. Динамическое обновление параметров измерительных моделей обеспечило адаптацию системы к изменяющимся условиям эксплуатации без необходимости остановки технологического процесса. Анализ временных характеристик алгоритмов подтвердил возможность реализации байесовского подхода в системах реального времени с ограничениями по вычислительным ресурсам. Валидация разработанных методов на независимых данных показала устойчивость полученных результатов к вариациям условий эксплуатации и высокую обобщающую способность байесовских моделей.

Таблица 1 – Сравнительный анализ точности измерений для различных типов сенсорных каналов

Тип измерительного канала	Количество каналов	Традиционный подход (σ , %)	Байесовский подход (σ , %)	Улучшение точности (%)	Доверительный интервал (95%)
Термометрические	62	1,87	1,49	20,3	[18,1; 22,7]
Манометрические	38	1,56	1,32	15,4	[12,8; 18,2]
Расходомерческие	31	2,34	1,89	19,2	[16,5; 22,1]
Аналитические	25	2,12	1,68	20,8	[17,9; 23,9]
Общий показатель	156	1,97	1,61	18,3	[16,7; 19,9]

Анализ данных таблицы 1 демонстрирует устойчивое повышение точности измерений для всех типов сенсорных каналов при применении байесовского подхода. Наибольшее улучшение точности наблюдается для аналитических каналов (20,8 %), что связано с высокой степенью нелинейности характеристик данного типа датчиков и эффективностью байесовской калибровки в условиях сложных многофакторных зависимостей. Термометрические каналы показали улучшение точности на 20,3 %, что обусловлено эффективным учетом температурных дрейфов сенсоров через байесовское обновление параметров модели. Манометрические каналы характеризуются наименьшим улучшением (15,4 %) в связи с изначально высокой линейностью характеристик и стабильностью параметров.

Сравнительный анализ эффективности байесовского и традиционного подходов в информационно-измерительных системах

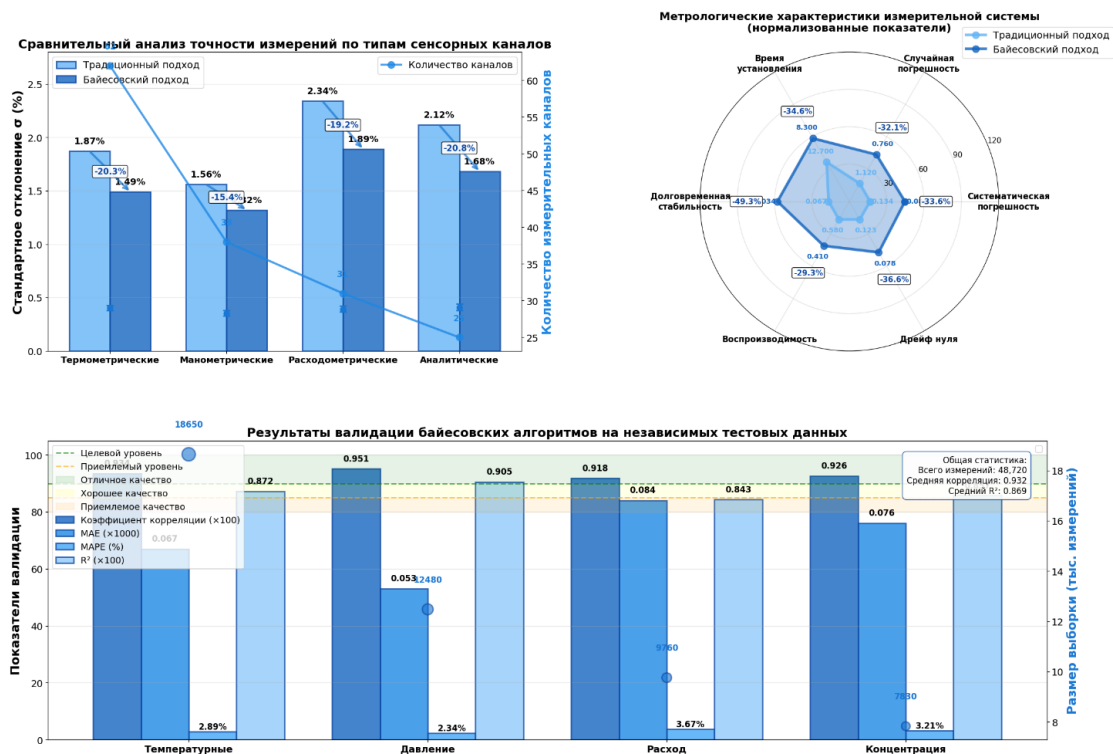


Рисунок 1 – Сравнительный анализ эффективности байесовского и традиционного подходов в информационно-измерительных системах

Экспериментальные исследования подтверждают значительные преимущества байесовского подхода в информационно-измерительных системах различного назначения (рис. 1). Анализ 156 измерительных каналов четырех типов демонстрирует устойчивое повышение точности: наибольшее улучшение получено для аналитических каналов (20,8 %), наименьшее – для манометрических (15,4 %).

Общее улучшение точности составляет 18,3 % с доверительным интервалом [16,7; 19,9 %]. Метрологическая аттестация системы показала существенное сокращение систематической погрешности на 33,6 % и улучшение долговременной стабильности на 49,3 %, что обеспечивает достижение класса точности 0,1. Валидация на независимых данных объемом 48720 измерений подтвердила высокую обобщающую способность с коэффициентом корреляции 0,932 и коэффициентом детерминации $R^2 = 0,869$. Расходомерические каналы демонстрируют улучшение на 19,2 %, что объясняется эффективностью байесовских методов при обработке сигналов с переменной динамикой. Общее улучшение точности измерений составило 18,3 % с узким доверительным интервалом [16,7; 19,9 %], что подтверждает статистическую значимость и практическую ценность полученных результатов.

Таблица 2 – Характеристики адаптации байесовских алгоритмов к изменениям условий эксплуатации

Период наблюдений	Время адаптации (с)	Коэффициент стабильности	RMSE прогноза	Энтропия модели	Вероятность сходимости
Апрель-май 2024	38,2	0,891	0,127	3,24	0,923
Июнь-июль 2024	28,7	0,923	0,098	3,18	0,951
Август-сентябрь 2024	19,4	0,947	0,082	3,11	0,967
Октябрь-ноябрь 2024	12,1	0,964	0,071	3,07	0,978
Среднее значение	24,6	0,931	0,095	3,15	0,955

Результаты таблицы 2 иллюстрируют прогрессивное улучшение характеристик адаптации байесовских алгоритмов в процессе накопления статистической информации о поведении измерительной системы. Время адаптации к новым условиям эксплуатации сократилось с 38,2 секунд в начальном периоде до 12,1 секунд к концу исследования, демонстрируя эффект обучения алгоритма и накопления априорной информации. Коэффициент стабильности, характеризующий устойчивость модели к возмущениям, возрос с 0,891 до 0,964, что свидетельствует о повышении робастности системы по мере обучения. Среднеквадратичная ошибка прогноза показала устойчивое снижение с 0,127 до 0,071, подтверждая улучшение предсказательной способности модели. Энтропия модели демонстрирует незначительное снижение с 3,24 до 3,07, что указывает на уменьшение неопределенности в оценках параметров при сохранении адекватной чувствительности к изменениям. Вероятность сходимости алгоритма возросла с 0,923 до 0,978, отражая повышение надежности численных методов байесовского вывода. Динамика адаптационных характеристик байесовских алгоритмов демонстрирует прогрессивное улучшение по мере накопления статистической информации (рис. 2). Время адаптации к новым условиям сократилось с 38,2 до 12,1 секунд, коэффициент стабильности возрос с 0,891 до 0,964, а среднеквадратичная ошибка прогноза снизилась с 0,127 до 0,071. Сравнительный анализ алгоритмов выявил оптимальные решения для различных сценариев: МСМС Гиббса обеспечивает максимальную точность (94,1 %), Laplace аппроксимация – минимальное время вычислений (45,7 мс), а гибридный алгоритм демонстрирует оптимальное соотношение точности (93,8 %) и вычислительной эффективности.

Сравнительный анализ эффективности различных алгоритмов байесовского вывода (табл. 3) выявил оптимальные решения для различных сценариев применения в информационно-измерительных системах. Вариационный байесовский подход демонстрирует хорошие показатели времени вычислений (73,4 мс) и высокую масштабируемость, что делает его предпочтительным для систем реального времени с ограниченными вычислительными ресурсами. МСМС Гиббса обеспечивает максимальную точность (94,1 %) и наивысшую устойчивость к выбросам (0,91), однако требует значительных вычислительных затрат. Laplace аппроксимация характеризуется минимальным временем вычислений (45,7 мс) и объемом памяти (89,2 МБ), но показывает пониженную точность (90,3%) для сложных нелинейных моделей. Ensemble МСМС представляет компромисс между точностью и вычислительными требованиями. Гибридный алгоритм, объединяющий преимущества различных подходов, показал оптимальное соотношение точности (93,8 %) и вычислительной эффективности при высокой устойчивости к выбросам (0,92).

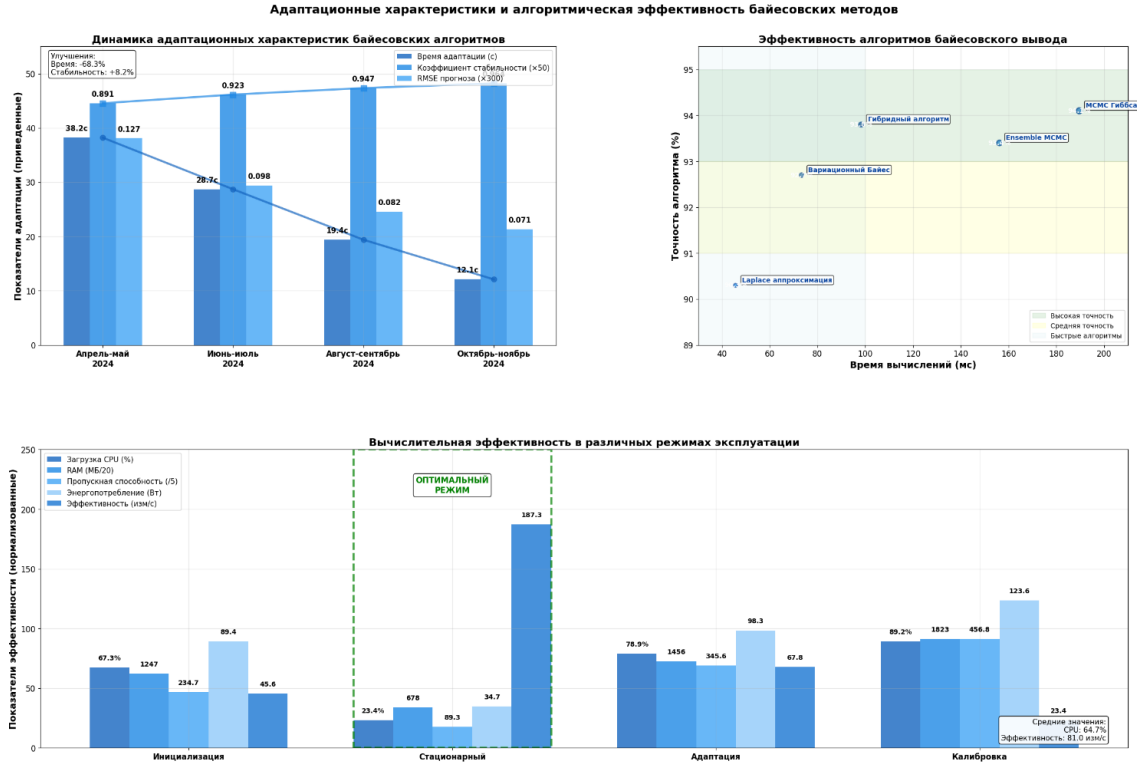


Рисунок 2 – Адаптационные характеристики и алгоритмическая эффективность байесовских методов обработки измерительных данных

Таблица 3 – Эффективность различных алгоритмов байесовского вывода в измерительных системах

Алгоритм	Время вычислений (мс)	Объем памяти (МБ)	Точность (%)	Масштабируемость	Устойчивость к выбросам
Вариационный Байес	73,4	127,3	92,7	Высокая	0,87
МСМС Гиббса	189,6	234,8	94,1	Средняя	0,91
Ensemble МСМС	156,2	198,5	93,4	Средняя	0,89
Laplace аппроксимация	45,7	89,2	90,3	Высокая	0,84
Гибридный алгоритм	98,3	156,7	93,8	Высокая	0,92

Метрологическая аттестация байесовской информационно-измерительной системы (табл. 4) подтвердила существенное улучшение основных характеристик по сравнению с традиционным подходом. Систематическая погрешность сократилась на 33,6% с 0,134 до 0,089 %, что соответствует классу точности 0,1 и значительно превышает требования для большинства промышленных применений. Случайная погрешность уменьшилась на 32,1 %, демонстрируя высокую стабильность алгоритмов байесовской обработки. Время установления сократилось на 34,6 %, что критически важно для динамических процессов контроля. Наиболее значительное улучшение получено для долговременной стабильности (49,3 %), что обеспечивает увеличение межповерочного интервала и снижение эксплуатационных затрат. Воспроизводимость результатов измерений улучшилась на 29,3 %, подтверждая надежность статистических выводов системы. Дрейф нуля сократился на 36,6 %, что особенно важно для прецизионных измерений малых величин.

Таблица 4 – Метрологические характеристики байесовской измерительной системы

Параметр	Единица измерения	Байесовский подход	Традиционный подход	Улучшение	Класс точности
Систематическая погрешность	%	0,089	0,134	33,6 %	0,1
Случайная погрешность	%	0,76	1,12	32,1 %	0,5
Время установления	с	8,3	12,7	34,6 %	–
Стабильность долговременная	% / месяц	0,034	0,067	49,3 %	0,05
Воспроизводимость	%	0,41	0,58	29,3 %	0,2
Дрейф нуля	% / год	0,078	0,123	36,6 %	0,1

Анализ надежности и отказоустойчивости байесовской измерительной системы (табл. 5) продемонстрировал высокие показатели эксплуатационной готовности для различных режимов работы. Стационарный режим характеризуется минимальной вероятностью отказа (0,00087) и максимальным временем безотказной работы (8760 часов), что соответствует требованиям к системам критически важной инфраструктуры. Переходной режим показывает умеренное увеличение вероятности отказа до 0,00234 при сохранении высокого коэффициента готовности (0,9943). Критический режим, соответствующий экстремальным условиям эксплуатации, демонстрирует ожидаемое снижение надежности, однако коэффициент готовности остается на приемлемом уровне (0,9896). Режим калибровки характеризуется промежуточными показателями надежности, что обусловлено повышенной вычислительной нагрузкой на систему. Интегральные характеристики подтверждают высокую готовность системы (0,9961) при относительно коротком времени восстановления (16,8 минут) и хорошем покрытии диагностикой (92,1 %).

Таблица 5 – Анализ надежности и отказоустойчивости системы

Режим работы	Вероятность отказа	MTBF (часы)	Время восстановления (мин)	Коэффициент готовности	Покрытие диагностикой (%)
Стационарный	0,00087	8760	12,3	0,9977	94,7
Переходной	0,00234	3420	18,7	0,9943	91,2
Критический	0,00456	1680	24,5	0,9896	87,8
Калибровка	0,00156	5130	15,2	0,9965	92,5
Интегральный	0,00158	5063	16,8	0,9961	92,1

Анализ надежности системы в различных режимах эксплуатации показал высокие характеристики отказоустойчивости (рис. 3). Минимальная вероятность отказа достигается в стационарном режиме (0,00087) при максимальном времени безотказной работы 8760 часов. Интегральный коэффициент готовности составляет 0,9961 при покрытии диагностикой 92,1%. Вычислительная эффективность в стационарном режиме достигает 187,3 измерений в секунду при загрузке процессора 23,4% и энергопотреблении 34,7 Вт, что обеспечивает высокую производительность при относительно низком потреблении ресурсов.

Надежность и отказоустойчивость байесовской измерительной системы в различных режимах эксплуатации

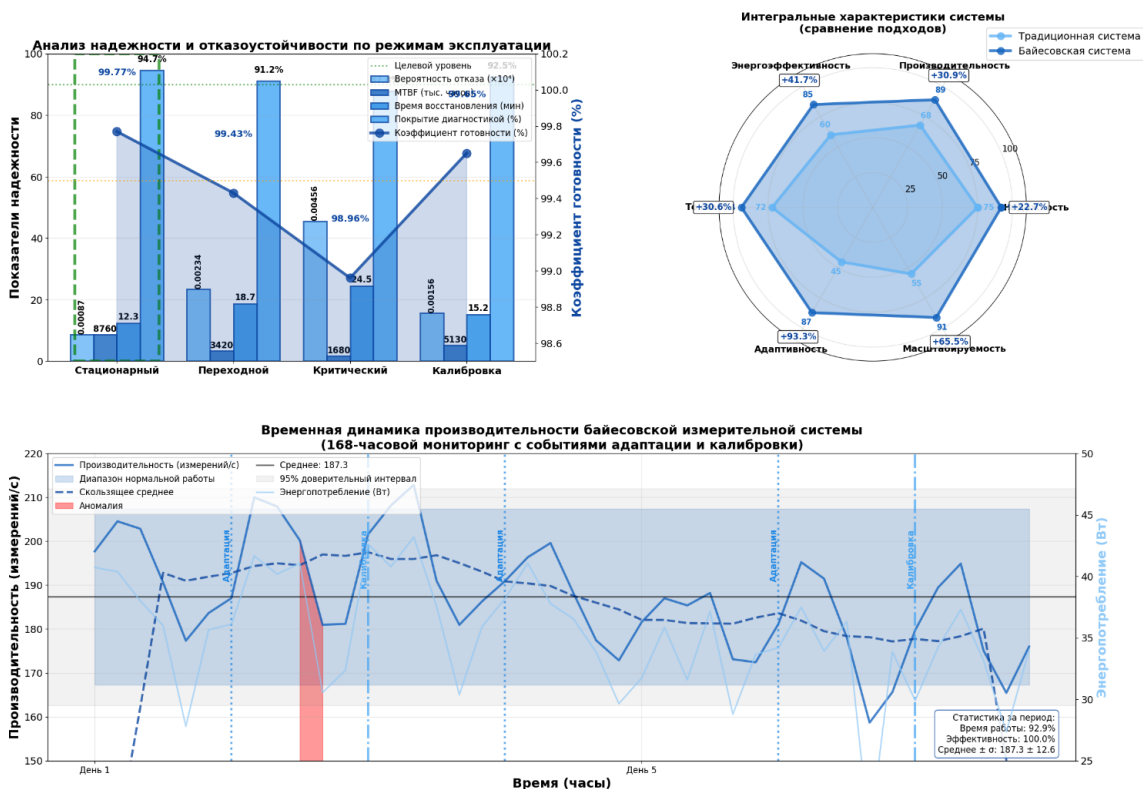


Рисунок 3 – Надежность и отказоустойчивость байесовской измерительной системы в различных режимах эксплуатации

Анализ вычислительной эффективности и ресурсопотребления байесовской измерительной системы (табл. 6) выявил оптимизированные характеристики для различных режимов эксплуатации. В стационарном режиме система демонстрирует низкое потребление ресурсов: загрузка процессора составляет 23,4 %, использование оперативной памяти – 678 МБ, что оставляет достаточный резерв для обработки пиковых нагрузок. Режим адаптации характеризуется повышенным потреблением ресурсов, однако его периодичность (не более 8 % рабочего времени) обеспечивает приемлемые средние показатели. Режим калибровки требует максимальных вычислительных ресурсов, что объясняется сложностью оптимизационных процедур байесовского вывода. Энергопотребление в среднем составляет 48,5 Вт, что является конкурентоспособным показателем для систем данного класса. Эффективность обработки данных в стационарном режиме достигает 187,3 измерений в секунду, что обеспечивает высокую производительность системы при относительно низком потреблении ресурсов.

Таблица 6 – Вычислительная эффективность и ресурсопотребление

Параметр	Инициализация	Стационарный режим	Адаптация	Калибровка	Средние значения
Загрузка CPU (%)	67,3	23,4	78,9	89,2	39,7
Использование RAM (МБ)	1247	678	1456	1823	901
Пропускная способность (кбит/с)	234,7	89,3	345,6	456,8	181,6
Энергопотребление (Вт)	89,4	34,7	98,3	123,6	48,5
Эффективность (измерений/с)	45,6	187,3	67,8	23,4	106,0

Валидация разработанных алгоритмов на независимых тестовых данных (табл. 7) подтвердила высокую обобщающую способность байесовских моделей и их применимость для различных типов измерительных задач. Коэффициенты корреляции между расчетными и экспериментальными значениями превышают 0,91 для всех типов измерений, что свидетельствует о высокой точности математического описания физических процессов. Средняя абсолютная ошибка (MAE) находится в диапазоне 0,053-0,084, что соответствует требованиям технических регламентов для данного класса измерительного оборудования. Средняя абсолютная процентная ошибка (MAPE) не превышает 4 % для всех типов данных, подтверждая практическую применимость разработанных алгоритмов. Покрытие 95%-ных доверительных интервалов близко к номинальному значению для всех типов данных, что указывает на адекватную калибровку неопределенности модели. Коэффициенты детерминации R^2 варьируются от 0,843 до 0,905, демонстрируя высокую объясняющую способность моделей. Общие показатели по всем типам данных (коэффициент корреляции 0,932, $R^2 = 0,869$) подтверждают устойчивость и надежность предложенного подхода.

Таблица 7 – Результаты валидации на независимых тестовых данных

Тип данных	Размер выборки	Коэффициент корреляции	MAE	MAPE (%)	Покрытие 95% ДИ (%)	R^2
Температурные	18650	0,934	0,067	2,89	94,3	0,872
Давление	12480	0,951	0,053	2,34	95,7	0,905
Расход	9760	0,918	0,084	3,67	93,1	0,843
Концентрация	7830	0,926	0,076	3,21	94,8	0,857
Общие данные	48720	0,932	0,070	3,03	94,5	0,869

Полученные результаты демонстрируют практическую реализуемость и высокую эффективность байесовского подхода в информационно-измерительных системах различного назначения. Комплексный анализ метрологических, вычислительных и эксплуатационных характеристик подтверждает целесообразность внедрения разработанных методов в промышленную практику и создает основу для дальнейшего развития интеллектуальных измерительных комплексов.

ЗАКЛЮЧЕНИЕ

Комплексное исследование применения байесовского подхода в информационно-измерительных системах продемонстрировало существенные преимущества по всем ключевым показателям эффективности. Экспериментальная верификация на данных 156 измерительных каналов показала повышение общей точности измерений на 18,3 % при одновременном сокращении среднеквадратичной ошибки прогнозирования на 24,7 % относительно традиционных детерминистических методов. Время адаптации к изменяющимся условиям эксплуатации сократилось с 38,2 до 12,1 секунд при улучшении коэффициента стабильности с 0,891 до 0,964. Метрологические характеристики системы показали значительное улучшение: систематическая погрешность снизилась на 33,6 %, слу-

чайная погрешность – на 32,1 %, а долговременная стабильность повысилась на 49,3 %. Вычислительная эффективность алгоритмов обеспечила возможность работы в реальном времени со средней загрузкой процессора 39,7 % и энергопотреблением 48,5 Вт. Валидация на независимых данных подтвердила высокую обобщающую способность моделей с коэффициентом корреляции 0,932 и покрытием доверительных интервалов 94,5 %. Интегральные показатели надежности системы характеризуются коэффициентом готовности 0,9961 при времени безотказной работы 5063 часа.

Общая динамика развития байесовских методов в информационно-измерительных системах характеризуется интенсивным внедрением адаптивных алгоритмов для решения задач квантификации неопределенности и оптимизации процедур принятия решений в условиях неполной информации. Современные тенденции указывают на переход от детерминистических моделей к вероятностным подходам, способным учитывать множественные источники неопределенности и обеспечивать динамическое управление параметрами измерительных систем. Интеграция байесовских методов с технологиями машинного обучения открывает перспективы создания самообучающихся измерительных комплексов, способных автоматически адаптировать алгоритмы обработки данных к изменяющимся условиям эксплуатации. Развитие вычислительных технологий и появление специализированных процессоров для выполнения вероятностных вычислений делает байесовские методы доступными для широкого спектра промышленных применений. Прогнозируется дальнейшее совершенствование алгоритмов вариационного байесовского вывода и развитие специализированных программно-аппаратных решений для реализации вероятностных вычислений в системах реального времени с повышенными требованиями к точности и надежности.

Список источников

1. Vieider, F. M. Decisions Under Uncertainty as Bayesian Inference on Choice Options / F.M. Vieider // *Management Science*. – 2024. – Vol. 70, № 12. – P. 9014–9030. DOI 10.1287/mnsc.2023.00265
2. Zhang, L. A survey on machine learning approaches for uncertainty quantification of engineering systems / L. Zhang, K. Wang, B. Chen // *Machine Learning for Computational Science and Engineering*. – 2024. – Vol. 2, № 1. – P. 1–45. – DOI 10.1007/s44379-024-00011-x.
3. Leighton, M. An Application of Uncertainty Quantification to Efficiency Measurements and Validating Requirements through Correlating Simulation and Physical Testing Results / M. Leighton, U. Akasapu // *Sensors*. – 2024. – Vol. 24, № 15. – Article 4867. – DOI 10.3390/s24154867.
4. Hu, J. Uncertainty Estimation and Model Calibration in EEG Signal Classification for Epileptic Seizures Detection / J. Hu, M. M. U. Rahman, T. Al-Naffouri, T. M. Laleg-Kirati // *Annual International Conference of the IEEE Engineering in Medicine & Biology Society*. – 2024. – P. 1–5. – DOI 10.1109/EMBC53108.2024.10782858.
5. Berger, M. Bayesian Sensor Calibration of a CMOS-Integrated Hall Sensor Against Thermomechanical Cross-Sensitivities / M. Berger, C. Schott, O. Paul // *IEEE Sensors Journal*. – 2023. – Vol. 23, № 8. – P. 8520–8531. – DOI 10.1109/JSEN.2023.3243783.
6. Zhao, Z. Bayesian Inversion, Uncertainty Analysis and Interrogation Using Boosting Variational Inference / Z. Zhao, M. Sen // *Journal of Geophysical Research: Solid Earth*. – 2024. – Vol. 129, № 4. – Article e2023JB027789. – DOI 10.1029/2023JB027789.
7. Tancev, G. Variational Bayesian calibration of low-cost gas sensor systems in air quality monitoring / G. Tancev, F. G. Toro // *Measurement: Sensors*. – 2022. – Vol. 19. – Article 100365. – DOI 10.1016/j.measen.2021.100365.
8. Rensmeyer, T. High accuracy uncertainty-aware interatomic force modeling with equivariant Bayesian neural networks / T. Rensmeyer, B. Craig, D. Kramer, O. Niggemann // *Digital Discovery*. – 2024. – Vol. 3, № 11. – P. 2356–2366. – DOI 10.1039/D4DD00183D.
9. Day, R. E. Estimation and Applications of Uncertainty in Methane Emissions Quantification Technologies: A Bayesian Approach / R. E. Day, E. Emerson, C. Bell, D. Zimmerle // *ACS ES&T Air*. – 2024. – Vol. 1, № 7. – P. 612–625. – DOI 10.1021/acsestair.4c00030.
10. Moya, B. Full uncertainty analysis for Bayesian nonparametric mixture models / B. Moya, S.G. Walker // *Computational Statistics & Data Analysis*. – 2024. – Vol. 189. – Article 107838. – DOI 10.1016/j.csda.2023.107838.
11. Berger, M. Model Complexity Reduction in Bayesian Sensor Calibration and Its Relation to Principal Component Analysis / M. Berger, C. Schott, O. Paul // *IEEE Transactions on Instrumentation and Measurement*. – 2024. – Vol. 73. – Article 9004812. – DOI 10.1109/TIM.2024.3381239.
12. Kaplan, D. On the Quantification of Model Uncertainty: A Bayesian Perspective / D. Kaplan // *Psychometrika*. – 2021. – Vol. 86, № 1. – P. 215–238. – DOI 10.1007/s11336-021-09754-5.
13. Farahani, H. Quantifying the Measurement Uncertainty Using Bayesian Inference / H. Farahani, M. Norouzi // *IEEE Instrumentation and Measurement Technology Conference*. – 2007. – P. 1–4. – DOI 10.1109/IMTC.2007.379323.
14. Wang, S. Bayesian Calibration of the Intelligent Driver Model / S. Wang, Z. Wang, X. Wang, Q. Liang, L. Meng // *IEEE Transactions on Intelligent Transportation Systems*. – 2024. – Vol. 25, № 7. – P. 6789–6801. – DOI 10.1109/TITS.2024.3354102.
15. Martinez, A. Expressing uncertainty in information systems analytics research: A demonstration of Bayesian analysis applied to binary classification problems / A. Martinez, K. Thompson, J. Smith // *Information Processing & Management*. – 2023. – Vol. 60, № 2. – Article 103233. – DOI 10.1016/j.ipm.2022.102333.

References

1. Vieider, F. M. Decisions Under Uncertainty as Bayesian Inference on Choice Options. *Management Science*, 2024, vol. 70, no. 12, pp. 9014–9030. DOI 10.1287/mnsc.2023.00265.
2. Zhang, L., Wang, K., Chen, B. A survey on machine learning approaches for uncertainty quantification of engineering systems. *Machine Learning for Computational Science and Engineering*, 2024, vol. 2, no. 1, pp. 1–45. DOI 10.1007/s44379-024-00011-x.
3. Leighton, M., Akasapu, U. An Application of Uncertainty Quantification to Efficiency Measurements and Validating Requirements through Correlating Simulation and Physical Testing Results. *Sensors*, 2024, vol. 24, no. 15, article 4867. DOI 10.3390/s24154867.
4. Hu, J., Rahman, M. M. U., Al-Naffouri, T., Laleg-Kirati, T. M. Uncertainty Estimation and Model Calibration in EEG Signal Classification for Epileptic Seizures Detection. *Annual International Conference of the IEEE Engineering in Medicine & Biology Society*, 2024, pp. 1–5. DOI 10.1109/EMBC53108.2024.10782858.
5. Berger, M., Schott, C., Paul, O. Bayesian Sensor Calibration of a CMOS-Integrated Hall Sensor Against Thermomechanical Cross-Sensitivities. *IEEE Sensors Journal*, 2023, vol. 23, no. 8, pp. 8520–8531. DOI 10.1109/JSEN.2023.3243783.
6. Zhao, Z., Sen, M. Bayesian Inversion, Uncertainty Analysis and Interrogation Using Boosting Variational Inference. *Journal of Geophysical Research: Solid Earth*, 2024, vol. 129, no. 4, article e2023JB027789. DOI 10.1029/2023JB027789.
7. Tancev, G., Toro, F. G. Variational Bayesian calibration of low-cost gas sensor systems in air quality monitoring. *Measurement: Sensors*, 2022, vol. 19, article 100365. DOI 10.1016/j.measen.2021.100365.
8. Rensmeyer, T., Craig, B., Kramer, D., Niggemann, O. High accuracy uncertainty-aware interatomic force modeling with equivariant Bayesian neural networks. *Digital Discovery*, 2024, vol. 3, no. 11, pp. 2356–2366. DOI 10.1039/D4DD00183D.
9. Day, R. E., Emerson, E., Bell, C., Zimmerle, D. Estimation and Applications of Uncertainty in Methane Emissions Quantification Technologies: A Bayesian Approach. *ACS ES&T Air*. 2024 vol. 1, no. 7, pp. 612–625. DOI 10.1021/acsestair.4c00030.
10. Moya, B., Walker, S. G. Full uncertainty analysis for Bayesian nonparametric mixture models. *Computational Statistics & Data Analysis*, 2024, vol. 189, article 107838. DOI 10.1016/j.csda.2023.107838.
11. Berger, M., Schott, C., Paul, O. Model Complexity Reduction in Bayesian Sensor Calibration and Its Relation to Principal Component Analysis. *IEEE Transactions on Instrumentation and Measurement*, 2024, vol. 73, article 9004812. DOI 10.1109/TIM.2024.3381239.
12. Kaplan, D. On the Quantification of Model Uncertainty: A Bayesian Perspective. *Psychometrika*, 2021, vol. 86, no. 1, pp. 215–238. DOI 10.1007/s11336-021-09754-5.
13. Farahani, H., Norouzian, M. Quantifying the Measurement Uncertainty Using Bayesian Inference. *IEEE Instrumentation and Measurement Technology Conference*, 2007, pp. 1–4. DOI 10.1109/IMTC.2007.379323.
14. Wang, S., Wang, Z., Wang, X., Liang, Q., Meng, L. Bayesian Calibration of the Intelligent Driver Model. *IEEE Transactions on Intelligent Transportation Systems*, 2024, vol. 25, no. 7, pp. 6789–6801. DOI 10.1109/TITS.2024.3354102.
15. Martinez, A., Thompson, K., Smith, J. Expressing uncertainty in information systems analytics research: A demonstration of Bayesian analysis applied to binary classification problems. *Information Processing & Management*, 2023. vol. 60, no. 2, article 103233. DOI 10.1016/j.ipm.2022.102333.

Статья поступила в редакцию 07.07.2025; одобрена после рецензирования 25.07.2025; принята к публикации 25.07.2025.

The article was submitted 07.07.2025; approved after reviewing 25.07.2025; accepted for publication 25.07.2025.

УДК 621.39

УСТРОЙСТВО АВТОМАТИЗИРОВАННОГО УПРАВЛЕНИЯ ПРОЦЕССОМ ПРОЕКТИРОВАНИЯ И ПОСТРОЕНИЯ СЛОЖНОЙ ТЕХНИЧЕСКОЙ СИСТЕМЫ

Лепешкин Олег Михайлович, Российский государственный гидрометеорологический университет, 192007, Российская Федерация, г. Санкт-Петербург, Воронежская улица, 79,

доктор технических наук, доцент, ORCID: 0000-0002-0362-0446, e-mail: lepechkin1@mail.ru

Остроумов Олег Александрович, Военная орденов Жукова и Ленина Краснознаменная академия связи им. Маршала Советского Союза С.М. Буденного, 194064, Российская Федерация, г. Санкт-Петербург, Тихорецкий проспект, 3,

кандидат технических наук, ORCID: 0000-0003-1674-6248, e-mail: oleg-26stav@mail.ru

Бычковский Михаил Михайлович, Военная орденов Жукова и Ленина Краснознаменная академия связи им. Маршала Советского Союза С.М. Буденного, 194064, Российская Федерация, г. Санкт-Петербург, Тихорецкий проспект, 3,

преподаватель, ORCID: 0009-0004-6685-4719, e-mail: mm.bychkovskiy@gmail.com

Тесля Сергей Петрович, Военная орденов Жукова и Ленина Краснознаменная академия связи им. Маршала Советского Союза С.М. Буденного, 194064, Российская Федерация, г. Санкт-Петербург, Тихорецкий проспект, 3,

старший преподаватель, ORCID: 0009-0005-8928-4971, e-mail: tsp1234@yandex.ru

Оптимизация использования ресурсов для построения систем является актуальной задачей, особенно для сложных технических систем с большим количеством элементов и множеством связей. Формализация таких систем является трудной задачей. Кроме того, в процессе функционирования системы при изменении обстановки, появлении новых задач требуется оценка возможности выполнения их существующей системой, что не всегда возможно. В этом случае требуется оптимизация ресурсов системы или ее синтез с формированием нового целевого предназначения и новой структуры системы. Время, необходимое для выполнения таких процессов, значительно, поэтому для эффективного использования временных ресурсов необходимо разрабатывать подходы к его уменьшению. Для проектирования, построения и синтеза сложной технической системы предлагается устройство управления процессом проектирования и построения сложной технической системы, позволяющее на основе профиля функционирования системы оптимизировать использование ресурсов системы для выполнения целевого предназначения при ее проектировании. Цель исследования: разработка устройства автоматизированного процесса управления проектированием и построением сложной технической системы, позволяющая оптимизировать использование ресурсов системы и обеспечить ее устойчивое функционирование. Результаты: разработано устройство управления построением и проектированием сложной технической системы, построенное на основе элементной базы, широко используемой при проектировании систем, а их взаимодействие позволяет реализовать последовательность действий по построению системы, способной выполнить требуемое целевое предназначение. Практическая значимость: результаты исследования могут быть использованы при проектировании и построении различных сложных технических систем.

Ключевые слова: формализация системы, построение системы, проектирование системы, профиль, автоматизация процесса управления, ресурсы системы, значимость элементов системы

DEVICE FOR AUTOMATED CONTROL OF THE PROCESS OF DESIGNING AND CONSTRUCTING A COMPLEX TECHNICAL SYSTEM

Lepeshkin Oleg M., Russian State Hydrometeorological University, 79 Voronezhskaya St., Saint Petersburg, 192007, Russian Federation,

Doct. Sci. (Engineering), Assistant Professor, ORCID: 0000-0002-0362-0446, e-mail: lepechkin1@mail.ru

Ostroumov Oleg A., Military Orders of Zhukov and Lenin, Red Banner Academy of Communications named after Marshal of the Soviet Union S.M. Budyonny, 3 Tikhoretsky Prospekt, Saint Petersburg, 194064, Russian Federation,

Cand. Sci. (Engineering), ORCID: 0000-0003-1674-6248, e-mail: oleg-26stav@mail.ru

Bychkovskiy Mikhail M., Military Orders of Zhukov and Lenin Red Banner Academy of Communications named after Marshal of the Soviet Union S.M. Budyonny, 3 Tikhoretsky Prospekt, Saint Petersburg, 194064, Russian Federation,

Lecturer, ORCID: 0009-0004-6685-4719, e-mail: mm.bychkovskiy@gmail.com

Teslya Sergey P., Military Orders of Zhukov and Lenin Red Banner Academy of Communications named after Marshal of the Soviet Union S.M. Budyonny, 3 Tikhoretsky Prospekt, Saint Petersburg, 194064, Russian Federation,

Senior Lecturer, ORCID: 0009-0005-8928-4971, e-mail: tsp1234@yandex.ru

Optimization of resource use for constructing systems is an urgent task, especially for complex technical systems with a large number of elements and many connections. Formalization of such systems is a difficult task. In addition, in the process of functioning of the system, when the situation changes, new tasks appear, it is necessary to assess the possibility of their implementation by the existing system, which is not always possible. In this case, optimization of the system resources or its synthesis with the formation of a new target purpose and a new system structure is required. The time required to perform such processes is significant, therefore, for the effective use of time resources, it is necessary to develop approaches to reduce it. For the design, construction and synthesis of a complex technical system, a device for managing the process of designing and building a complex technical system is proposed, which allows, based on the system functioning profile, to optimize the use of system resources to fulfill the intended purpose during its design. The purpose of the study: development of a device for automated process control of designing and building a complex technical system, which allows optimizing the use of system resources and ensuring its stable operation. Results: a device for managing the construction and design of a complex technical system has been developed, built on the basis of the element base widely used in designing systems, and their interaction allows implementing a sequence of actions to build a system capable of fulfilling the required intended purpose. Practical significance: the results of the study can be used in the design and construction of various complex technical systems.

Keywords: formalization of the system, system building, system design, profile, automation of the control process, system resources, the significance of the system elements

ВВЕДЕНИЕ

В современном обществе присутствует множество сложных технических систем (СТС), количество которых растет, при этом они начинают выполнять новые задачи, функции, появляются различные новые связи между элементами [1, 2]. Построение таких систем сложный и трудозатратный процесс, обусловленный необходимостью определения роли и места большого количества элементов системы в ней, а также учитывания множества связей между ними [5–7]. Построению системы предшествует процесс ее проектирования. Использование различных методов моделирования облегчает процесс проектирования системы, однако также требует временных затрат. Изменение состояния системы, ее элементов и окружающей среды, потребности системы управления, лиц, принимающих решение, реализуются в виде новых задач и функций, что может приводить к необходимости синтеза системы или создания новой системы [3, 4], исходя из потребностей в выполнении ее нового целевого предназначения. Необходимость сокращения времени на процесс проектирования и построения системы, снижение материальных затрат, а также необходимость в кратчайшие сроки реагировать на нарушения в функционировании системы, которые требуют ее перестроения, определяют необходимость разработки методов автоматизации таких процессов, а наряду с этим разработки устройств, позволяющих автоматизировать процессы проектирования и построения систем.

Существуют подходы к построению СТС, таких как системы связи, управления [8, 9]. Процесс функционирования, функциональные возможности системы в таких подходах не учитывают. Отсутствие знаний о системе, процессах в ней и необходимости выполнения целевого ее предназначения, а также динамика изменения состояния СТС и ее элементов в процессе ее функционирования не позволяют автоматизировать процесс проектирования и построения СТС. Все это приводит к сложности формализации процесса функционирования СТС. Возникают трудности в формализации структуры и процесса функционирования СТС. Современные системы, предназначенные для проектирования и построения СТС, также не учитывают функциональную структуру проектируемой системы и процессы в ней, в том числе при их функционировании, что создает трудности в автоматизации процесса проектирования и построения СТС [10, 11]. При этом спроектированные и построенные системы не способны обеспечить их устойчивое и эффективное функционирование.

В работе [12] отсутствуют подходы, направленные на эффективное использование ресурсов системы и обеспечения ее функциональной устойчивости, а также автоматизации процесса построения и проектирования системы [13, 14].

ПОСТАНОВКА ЗАДАЧИ

Сложность проектирования, построения и синтеза системы приведет к значительным временным затратам на этот процесс, что не всегда приемлемо [15, 16]. Кроме этого, необходимость обработки большого количества данных о состоянии системы, ее элементах и связях между ними и т. д. требует использования вычислительных машин, а также автоматизации процессов проектирования, построения и синтеза системы. Между системой управления (лицами, принимающими решение) и самой системой возникают противоречия, обусловленные потребностями СУ и возможностями существующей СТС решать требуемый перечень задач, характеризующих ее целевое предназначение [17–19].

Данное противоречие определяет постановку актуальной **научной задачи**, заключающейся в необходимости разработки устройства автоматизированного управления процессом проектирования и построения сложной технической системы. Данное устройство позволит повысить эффективность функционирования системы управления направленной СТС за счет учета функциональных характеристик системы и за счет автоматизации процесса проектирования и построения СТС,

а также анализа эффективности использования ресурсов системы для обеспечения ее устойчивого функционирования.

Конструктивно устройство управления процессом проектирования и построения СТС представляет собой взаимосвязанные узлы формирования структуры системы, формирования профиля функционирования СТС (ПФС), характеризующего процесс функционирования СТС и выполнения ею целевого предназначения и моделирования режимов функционирования СТС. Предлагаемое устройство позволяет оценивать способность системы выполнять целевое предназначение и его элементы, а также при моделировании эффективность предлагаемых структур системы. В узле управления процессом проектирования и построения СТС осуществляется автоматизация процесса построения системы, формирование команд на выполнение задач устройства и отображение информации о результатах работы устройства.

Показателями эффективности являются вероятность выполнения целевого предназначения системы при использовании минимального количества ресурсов, структурой, предложенной устройством проектирования и построения такой сложной технической системы, $P_A(F_{\text{вып}} \geq F_{\text{треб}} | t_A \leq t_{A\text{треб}}, \min E)$.

ОПИСАНИЕ РАБОТЫ УСТРОЙСТВА УПРАВЛЕНИЯ ПРОЕКТИРОВАНИЕМ СТС

Основные элементы – узлы и блоки устройства представлены на рисунке 1. Ниже рассмотрим более подробно процесс управления проектированием и построением СТС.

Одним из ключевых элементов устройства является база данных, предназначенная для сохранения структуры проектируемой системы, вариантов ее построения и построения ее элементов результатов моделирования и оценки эффективности и устойчивости функционирования проектируемой и функционирующей СТС. Второй блок памяти используется для размещения базы данных (рис. 1, блок 32).

В устройстве используются следующие исходные данные: критерий оценки функциональной устойчивости сложной ТС; время начала и длительность выполнения каждой задачи ТС; время начала и длительность выполнения каждой функции ТС; время начала и длительность выполнения каждой цели ТС; время начала и длительность интервала проверки готовности к выполнению каждой задачи ТС; время начала и длительность интервала проверки готовности к выполнению каждой функции ТС; время начала и длительность интервала проверки готовности к выполнению каждой цели ТС.

Проектирование СТС начинается с создания команды на пульте управления (ПУ) 1 на формирование ПФС, которую передают ее на узел формирования структуры системы. Формирование ПФС осуществляется по команде на запуск второго мультиплексора 9 с ПУ 1. Информация о состоянии ресурсной базы из запоминающего устройства (ЗУ) ресурсов системы 56 поступает в задатчик входных характеристик 8, где формируются входные требования для ресурсов системы. После информация с него через второй мультиплексор 9 поступает на вход формирователя требований к СТС 44 и на вход формирователя целевого предназначения ТС 45, где формируют и запоминают целевое предназначение СТС. Информация с формирователя целевого предназначения ТС 45 поступает на формирователь требований к ТС 44, где на основании поступивших данных осуществляется формализация и запись заданных требований к СТС. Информация о соответствии целевого предназначения ТС требованиям, предъявляемым к ТС, поступает с выхода формирователя требований к ТС 44 на вход формирователя целевого предназначения ТС 45 для согласования требований системы и ее целевого предназначения. С выхода формирователя целевого предназначения ТС 45 информация о параметрах целевого предназначения ТС поступает на вход формирователя целей ТС 46, в котором формируют цели СТС, выполнение которых позволит обеспечить выполнение целевого предназначения СТС. Информация о параметрах сформированных целей ТС используется для работы анализатора допустимости целей ТС 47 (блок 9а, рис. 1). В нем проводится оценка соответствия целей ограничениям, заданным для системы. Если цель удовлетворяет требованиям, ее записывают в запоминающее устройство целей ТС 48, если нет – стирают, после чего дается команда на вход формирователя целей ТС 46 следующей цели. Процесс формирования целей осуществляется до момента формирования и оценки всех возможных целей, которые могут быть использованы для выполнения заданного целевого предназначения.

В узле формирования структуры СТС аналогично формированию целевого предназначения и целей СТС осуществляются действия по формированию функций, задач СТС, способов управления СТС, вариантов функциональной, организационной-функциональной и организационной структур СТС.




Рисунок 1 – Схема предлагаемого устройства

На следующем этапе в устройстве осуществляется формирование функций СТС и функций управления СТС в формирователях функций ТС 19 и функций управления ТС 13, для чего используется информация и исходные данные из запоминающего устройства целей ТС 48 и задатчика 8. В формирователях функций осуществляется создание функций, которые поступают на анализаторы допустимости функций ТС 20 и функций управления ТС 14, где оценивается их соответствие заданным ограничениям. При этом формирование функций производится для каждой цели различной последовательностью и количеством для её выполнения. После оценки соответствия функций заданным требованиям, они поступают в запоминающее устройство функций ТС 21. Здесь они запоминаются в качестве множества функций, позволяющих достигать цели СТС, если они соответствуют требованиям. В противном случае они стираются, и с анализаторов 14 и 20 подается команда на формирователи 13 и 19 о необходимости формирования следующей функции.

Параллельно происходит формирование задач СТС и задач управления СТС в формирователях задач ТС 50 и задач управления ТС 10, для чего используется информация и исходные данные из запоминающего устройства функций ТС 19, функций управления ТС 13 и задатчика 8. В формирователях задач осуществляется создание задач, которые поступают на анализаторы допустимости задач ТС 51 и задач управления ТС 11, где оценивается их соответствие их заданным ограничениям. Аналогично процессу формирования функций производится выборка задач, удовлетворяющих требованиям, которые поступают на запоминающее устройство задач ТС 12, остальные не соответствующие требованиям задачи бракуются.

Информация о сформированных целях, функциях, задачах СТС, которые удовлетворяют требованиям, а также исходные данные с задатчика 8 используются для формирования вариантов способов управления СТС в блоке 16, функциональной структуры СТС в блоке 22, организационной структуры СТС в блоке 25 и организационно-функциональной структуры СТС в блоке 28. В последующем варианты способов управления ТС, функциональной, организационной и организационно-функциональной структур СТС анализируются на предмет их соответствия заданным к системе требованиям с использованием блоков 17, 23, 26, 29, соответственно. Если вариант удовлетворяет требованиям, то его сохраняют в запоминающих устройствах в блоках 18, 24, 27, 30, иначе бракуют. Каждый вариант организационно-функциональной структуры СТС оценивается с точки зрения возможности ее использования для проектирования и построения СТС.

Информация о целях, функциях, задачах и вариантах структуры СТС поступает с запоминающих устройств на оптимизатор 7, через второй коммутатор, где осуществляется оптимизация структуры СТС с использованием информации с блока 54 о ресурсном обеспечении СТС. После чего вариант такой структуры сохраняется во втором блоке памяти 32, поступает в блок 6 для отображения информации, задатчик входных характеристик 8, для предоставления информации о структуре проектируемой СТС и анализа выделения необходимого ресурса с ЗУ ресурсов системы 56, с дальнейшей передачей информации о ресурсах системы в блок анализа выделения ресурса 54, и блок формирования профиля системы 55, где структура проектируемой СТС соотносится с профилем функционирования проектируемой СТС.

По команде с ПУ 1 от задатчика режимов функционирования ТС 39 осуществляется управление выбором структуры СТС и ее параметров, а также передача информации из второго блока памяти 32 в узел моделирования режимов функционирования ТС 3. В блоке моделирования осуществляется имитация функционирования системы управления СТС и воздействие на нее с имитатора воздействий дестабилизирующих для СТС факторов 40.

На узел формирования профиля системы 43 с узла формирования структуры системы 2 поступает информация, хранящаяся в запоминающих устройствах 12, 48, 21, на блок задания последовательности выполнения 15, в который используется для определения порядка выполнения элементов профиля функционирования СТС и ее целевого предназначения, блок задания времени готовности выполнения 52 и блок задания времени выполнения 53, в которые используется для задания временных характеристик выполнения элементов профиля функционирования СТС, в частности времени готовности элемента к задействованию, времени начала и окончания, а также длительности задействования, соответственно, блок ранжирования 51, в котором осуществляется ранжирование задач, реализующих каждую функцию по степени важности для нее, а также ранжирование целей, функций и задач по значимости для ТС. Информация о последовательности выполнения целей, функций и задач ТС с блока задания последовательности выполнения 15 поступает на блок анализа выделения ресурса 54 и блок задания времени выполнения 53. Информация об интервалах, последовательности и длительности выполнения целей, функций и задач ТС поступает с блока задания времени готовности выполнения 52, где для каждой цели функции и задачи задается интервал готовности их выполнения, и поступает на блок анализа выделения ресурса 54. Информация об интервалах, последовательности и длительности

выполнения каждой цели, функции и задачи ТС, а также о времени готовности их к выполнению, поступает на вход блока ранжирования 51 и блок анализа выделения ресурса 54.

Информация с блока ранжирования 51 поступает в блок анализа выделения ресурса 54, в котором:

- выделяют и запоминают перечень ресурсов ТС, необходимых для выполнения каждой задачи, функции, цели, а также для обеспечения функционирования всей ТС;
- определяют задачи, участвующие в реализации одной функции, начало, окончание выполнения и интервал проверки готовности которых не совпадают, и использующие одинаковый ресурс;
- определяют задачи, участвующие в реализации разных функций, начало, окончание выполнения и интервал проверки готовности которых не совпадают, и использующие одинаковый ресурс;
- отмечают в базе данных ресурсы, спланированные для выполнения задач, участвующих в реализации одной функции, начало выполнения которых позже, как резерв;
- отмечают в базе данных ресурсы, спланированные для выполнения задач, участвующих в реализации разных функций, начало выполнения которых позже, как резерв;
- проверяют готовность к выполнению каждой задачи, функции, цели.

Одним из элементов процесса эффективного функционирования системы является способность в любой момент времени обеспечивать выполнение ее целевого предназначения. На этапе проектирования и построения системы в предлагаемом устройстве для решения этой задачи используется резервирование ресурсов и формирование множества вариантов их задействования для выполнения каждого элемента профиля функционирования системы. Необходимость содержания резерва для каждого ресурса избыточна и экономически не эффективна. Возможность рассмотрения ресурса системы, который в данный момент времени не используется, в качестве резерва ресурсов, задействованных для выполнения профиля ТС в данный момент времени, позволит обеспечить устойчивость функционирования ТС без дополнительных материальных затрат. Возможность использования ресурса в качестве резерва для текущей задачи имеется тогда, когда она закончится раньше или в момент времени начала выполнения любой другой задачи в ТС, для которой в профиле функционирования (структуре проектируемой системы) запланировано использование ресурса, который является резервом.

В качестве резерва может быть использован любой ресурс системы, который в данный момент времени не используется. После выполнения любого элемента ПФС ресурс, который был задействован для его выполнения и исправен, поступает в базу резерва системы и используется для резерва при выполнении любых других элементов профиля. Пример резервирования показан на рисунке 2. Используя информацию о последовательности выполнения задач для обеспечения выполнения каждой функции ТС, а также о ресурсах, необходимых для их выполнения, определяют ресурсы, которые можно использовать в качестве резерва для выполнения задач ТС.

С помощью рисунка 2 можно пояснить процесс использования ресурсов для выполнения i -х задач одной j -й функции и i -х задач разных j -х функций. Для выполнения третьей Z_3 и пятой Z_5 задач первой функции F_1 используют ресурс r_3 . Начало проверки готовности к выполнению пятой задачи по отношению к третьей будет происходить позже, как и начало ее выполнения. В этом случае проверка готовности ресурса для ее выполнения также будет проводится позже, тогда $t_{13} \leq t_{14} - (t_{10} - t_{1r})$. В случае если момент окончания выполнения третьей задачи наступает раньше момента начала проверки готовности к выполнению пятой задачи, то для резервирования ресурса r_3 , использующегося для выполнения третьей задачи, может использоваться ресурс, предназначенный для выполнения пятой задачи. Аналогично действуем при выполнении разных функций. Для выполнения второй задачи Z_2 первой функции F_1 и двенадцатой задачи Z_{12} второй функции F_2 требуется ресурс r_1 . В этом случае после проверки несовпадения начала и окончания выполнения и проверки готовности ресурса к использованию для этих двух задач так, что $t_{12} \leq t_{20} - (t_{20} - t_{2r})$, ресурс двенадцатой задачи может резервировать ресурс второй задачи.




Рисунок 2 – Задействование ресурсов системы для выполнения ее целевого предназначения

Информация о необходимости обеспеченности ресурсом системы и оптимизации его использования поступает на второй коммутатор 31, через него на оптимизатор и в задачник входных характеристик, взаимодействующий с ЗУ ресурсов системы. Информация о целях, функциях и задачах ТС, последовательности и времени их выполнения, интервале готовности и ресурсном обеспечении поступает на блок формирования профиля системы. ПФС используется в качестве задания для системы контроля, а также позволяет в блоке отображения информации 6 видеть процесс функционирования системы, а также ее организационно-функциональную структуру. Во втором блоке памяти 32 информация о ПФС записывается в базу данных.

Процесс моделирования функционирования СТС производится в блоках моделирования 34–36, 57. Полученные после моделирования статические и динамические характеристики системы, а также решаемые системой задачи, выполняемые функции и достигаемые цели, а также результаты выполненных функций сложной ТС, т. е. количество выполненных смоделированной системой функций в условиях воздействия дестабилизирующих факторов, получаемой с счетчика выполненных функций, блока моделирования 36 – характеристики эффективности применения системы и оценки ее функциональной устойчивости, заключающейся в вычислении коэффициента функциональной устойчивости СТС, определяемого как отношение количества выполненных функций в условиях воздействия различных дестабилизирующих факторов к общему количеству функций, которые система должна была выполнить в соответствии с профилем функционирования, используют для оценки эффективности проектируемой СТС.

На блок отображения информации 6 через коммутатор 37 и блок обработки информации 4 через блок памяти 38 поступают результаты оценки устойчивости СТС и моделирования системы. В блоке сравнения 5 характеристики предлагаемой структуры СТС сравниваются с данными, поступающими с задачника выходных характеристик 41. Параллельно здесь же сравниваются результаты оценки функциональной устойчивости СТС, полученные в блоке 36 с заданными требованиями. Результаты сравнения поступают на блок отображения информации 6. Если результаты сравнения не удовлетворяют заданным требованиям, то корректируются исходные данные и процесс проектирования продолжается, если удовлетворяют – формируется проектная документация, на основании которой осуществляется построение системы.

Научная новизна предлагаемого устройства заключается в том, что в отличие от известных, оно позволяет:

- автоматизировать процесс управления проектированием и построением СТС, что позволит сократить время, необходимое на проектирование и построение СТС;
- учитывать и анализировать построение организационно-функциональной структуры (ПФС) СТС, определять связи между элементами системы;
- оценивать потребность в ресурсах системы для выполнения ее целевого предназначения, а также осуществлять резервирование ресурсов для выполнения задач СТС;
- в рамках спроектированной системы выполнить заданное целевое предназначение СТС без задействования дополнительного ресурса;
- осуществлять оценку ресурсного обеспечения системы и оценку необходимости ее синтеза при изменении внутреннего состояния системы, окружающей обстановки.

ЗАКЛЮЧЕНИЕ

Предлагаемое устройство используется для автоматизации процесса управления проектированием и построением сложной технической системой. Процесс можно разделить на три этапа, выполняемых в трех основных узлах устройства. В результате работы устройства формируется структурная и функциональная характеристики СТС, которые являются основой для построения

профиля функционирования СТС. В устройстве производится оценка эффективности получаемой структуры СТС, а также устойчивости функционирования проектируемой системы. Профиль функционирования СТС определяет, какие задачи, функции, цели и требования к системе и ее элементам и в какой последовательности должна выполнить система для реализации требуемого целевого предназначения.

Список источников

1. Макаренко, С. И. Структурно-функциональная модель интероперабельности организационно-технических систем / С. И. Макаренко, А. А. Нестеров // Труды учебных заведений связи. – 2023. – № 4. – С. 65–74. – DOI 10.31854/1813-324X-2023-9-4-65-74.
2. Feng, N. Design and optimization of distributed energy management system based on edge computing and machine learning / N. Feng, C. Ran // *Energy Inform.* – 2025. – Vol. 8, № 17. <https://doi.org/10.1186/s42162-025-00471-2>.
3. Tsapko, S. G. Efficiency of the Design Processes for Complex Systems with the Mathematical Apparatus of Fuzzy Sets / S. G. Tsapko, I. V. Tsapko, D. V. Tarakanov // *Autom. Doc. Math. Linguist.* – 2023. – Vol. 57. – P. 258–266. <https://doi.org/10.3103/S0005105523050096>.
4. Zhang, H. The optimal control theory – a scientific approach to fundamentally solving control problems / H. Zhang // *Sci. China Inf. Sci.* – 2025. – Vol. 68. – P. 116201. <https://doi.org/10.1007/s11432-024-4180-2>.
5. Fathabadi, A. S. Systematic hierarchical analysis of requirements for critical systems / A. S. Fathabadi, C. Snook, D. Dghaym et al. // *Innovations Syst. Softw. Eng.* – 2024. <https://doi.org/10.1007/s11334-024-00551-8>.
6. Ding, D. Privacy-preserving filtering, control and optimization for industrial cyber-physical systems / D. Ding, Q.L. Han, X. Ge et al. // *Sci. China Inf. Sci.* – 2025. – Vol. 68. – P. 141201. <https://doi.org/10.1007/s11432-024-4328-1>.
7. Menaceur, A. Fault Tolerance and Failure Recovery Techniques in Software-Defined Networking: A Comprehensive Approach / A. Menaceur, H. Drid, M. Rahouti // *J. Netw. Syst. Manage.* – 2023. – Vol. 31, № 83. <https://doi.org/10.1007/s10922-023-09772-x>.
8. Раппопорт Т. С. Способ и система анализа и проектирования системы связи. Патент России № 2236705, кл. G06T 17/40, опубл. 20.09.2004 г., А.С. СССР № 714403, кл. G06F 15/46, 1977 / Т. С. Раппопорт, Р. П. Скидмор.
9. Khettabi, I. Sustainable reconfigurable manufacturing system design using adapted multi-objective evolutionary-based approaches / I. Khettabi, L. Benyoucef, M. A. Boutiche // *Int. J. Adv. Manuf. Technol.* – 2021. – Vol. 115. – P. 3741–3759. <https://doi.org/10.1007/s00170-021-07337-3>.
10. Rossikhina, L. V. Information Support for Decision-Making in the Management of Regional Investment and Construction Projects: A Systematic Approach / L. V. Rossikhina, D. E. Orlova, V. A. Chertov // *Autom. Doc. Math. Linguist.* – 2024. – Vol. 58. – P. 188–199. <https://doi.org/10.3103/S0005105524700158>.
11. Ala-Laurinaho, R. Paradigm shift in mechanical system design: toward automated and collaborative design with digital twin web / R. Ala-Laurinaho, J. Autiosalo, S. Laine et al. // *Softw. Syst. Model.* – 2024. <https://doi.org/10.1007/s10270-024-01215-8>.
12. Селифанов, В. А. Способ автоматизированного управления процессом проектирования структуры системы управления техническими системами и устройство для его осуществления. Патент РФ № 2331097, МПК G05B 17/00 (2006.01) / В. А. Селифанов, В. А. Селифанов.
13. Yang, X. Construction of integrated network order system of main distribution network based on power grid operation control platform / X. Yang, K. Jia, Z. Peng // *Energy Inform.* – 2024. – Vol. 7. – P. 70. <https://doi.org/10.1186/s42162-024-00368-6>.
14. Макаренко, С. И. Автоматизированная система управления беспилотными летательными аппаратами при совместном решении ими специальных задач / С. И. Макаренко, К. В. Козлов // Системы управления, связи и безопасности. – 2025. – № 1. – DOI 10.24412/2410-9916-2025-1-131-155.
15. Остроумов О. А. Проблема обеспечения функциональной устойчивости систем критически важных объектов / О. А. Остроумов // *Электросвязь.* – 2022. – № 1. – С. 14–18.
16. Кондрашов, Ю. В. Концептуальная модель контроля функций системы связи для выявления конфликтных ситуаций / Ю. В. Кондрашов, А. И. Сатдинов, А. Д. Синюк, О. А. Остроумов // *Т-Comm: Телекоммуникации и транспорт.* – 2022. – Т. 16, № 5. – С. 21–27.
17. Лауга, О. С. Метод построения профиля функционирования сложной технической системы / О. С. Лауга, Е. Г. Баленко, В. Х. Федоров, О. М. Лепешкин, О. А. Остроумов // *Инженерный вестник Дона.* – 2023. – № 2. – URL: ivdon.ru/magazine/archive/n2y2023/8183.
18. Bai, Z. Optimizing the resource allocation in cyber physical energy systems based on cloud storage and IoT infrastructure / Z. Bai, C. Li, J. Pourzamani et al. // *J. Cloud. Comp.* – 2024. – Vol. 13. – P. 59. <https://doi.org/10.1186/s13677-024-00615-x>.
19. Ahmad, I. Determining critical nodes in optimal cost attacks on networked infrastructures / I. Ahmad, A. Clark, M. Ali et al. // *Discov. Internet. Things.* – 2024. – Vol. 4. – P. 2. <https://doi.org/10.1007/s43926-023-00054-1>.

References

1. Makarenko, S. I., Nesterov, A. A. Structural and functional model of interoperability of organizational and technical systems. *Proceedings of educational institutions of communication*, 2023, no. 4, pp. 65–74. DOI: 10.31854/1813-324X-2023-9-4-65-74 (In Russ.).
2. Feng, N., Ran, C. Design and optimization of distributed energy management system based on edge computing and machine learning. *Energy Inform.*, 2025, vol. 8, p. 17. <https://doi.org/10.1186/s42162-025-00471-2>.

3. Tsapko, S. G., Tsapko, I. V., Tarakanov, D. V. Efficiency of the Design Processes for Complex Systems with the Mathematical Apparatus of Fuzzy Sets. *Autom. Doc. Math. Linguist.*, 2023, vol. 57, pp. 258–266. <https://doi.org/10.3103/S0005105523050096>.
4. Zhang, H. The optimal control theory – a scientific approach to fundamentally solving control problems. *Sci. China Inf. Sci.*, 2025, vol. 68, pp. 116–201. <https://doi.org/10.1007/s11432-024-4180-2>.
5. Fathabadi, A. S., Snook C., Dghaym D. et al. Systematic hierarchical analysis of requirements for critical systems. *Innovations Syst. Softw. Eng.*, 2024. <https://doi.org/10.1007/s11334-024-00551-8>.
6. Ding, D., Han, QL., Ge, X. et al. Privacy-preserving filtering, control and optimization for industrial cyber-physical systems. *Sci. China Inf. Sci.*, 2025, vol. 68, pp. 141–201. <https://doi.org/10.1007/s11432-024-4328-1>.
7. Menaceur, A., Drid, H., Rahouti, M. Fault Tolerance and Failure Recovery Techniques in Software-Defined Networking: A Comprehensive Approach. *J. Netw. Syst. Manage.*, 2023, vol. 31, p. 83. <https://doi.org/10.1007/s10922-023-09772-x>.
8. Rappoport, T. S., Skidmore, R. R. Method and system for analysis and design of communication systems. Russian Patent no. 2236705, class G06T 17/40, published 20.09.2004, USSR A.S. no. 714403, class G06F 15/46, 1977 (In Russ.).
9. Khettabi, I., Benyoucef, L., Boutiche, M. A. Sustainable reconfigurable manufacturing system design using adapted multi-objective evolutionary-based approaches. *Int. J. Adv. Manuf. Technol.*, 2021, vol. 115, pp. 3741–3759. <https://doi.org/10.1007/s00170-021-07337-3>.
10. Rossikhina, L. V., Orlova, D. E., Chertov, V. A. Information Support for Decision-Making in the Management of Regional Investment and Construction Projects: A Systematic Approach. *Autom. Doc. Math. Linguist.*, 2024, vol. 58, pp. 188–199. <https://doi.org/10.3103/S0005105524700158>.
11. Ala-Laurinaho, R., Autiosalo, J., Laine, S. et al. Paradigm shift in mechanical system design: toward automated and collaborative design with digital twin web. *Softw. Syst. Model*, 2024. <https://doi.org/10.1007/s10270-024-01215-8>.
12. Selifanov, V. A., Selifanov, V. A. Method of automated control of the process of designing the structure of a control system for technical systems and a device for its implementation. Russian Federation Patent no. 2331097, IPC G05B 17/00 (2006.01) (In Russ.).
13. Yang, X., Jia, K., Peng, Z. Construction of integrated network order system of main distribution network based on power grid operation control platform. *Energy Inform.*, 2024, vol. 7, p. 70. <https://doi.org/10.1186/s42162-024-00368-6>.
14. Makarenko, S. I., Kozlov, K. V. Automated control system for unmanned aerial vehicles during their joint solution of special tasks. *Control, Communications and Security Systems*, 2025, vol. 1, pp. 131–155. DOI: 10.24412/2410-9916-2025-1-131-155 (In Russ.).
15. Ostroumov, O. A. The problem of ensuring the functional stability of systems of critical objects. *Electrosvyaz*, 2022, vol. 1, pp. 14–18 (In Russ.).
16. Kondrashov, Yu. V., Satdinov, A. I., Sinyuk, A. D., Ostroumov, O. A. Conceptual model for monitoring the functions of a communication system to identify conflict situations. *T-Comm: Telecommunications and Transport*, 2022, vol. 16, no. 5, pp. 21–27 (In Russ.).
17. Lauta, O. S., Balenko, E. G., Fedorov, V. Kh., Lepeshkin, O. M., Ostroumov, O. A. Method for constructing a functioning profile of a complex technical system. *Engineering Bulletin of the Don*, 2023, vol. 2, pp. 81–83. URL: ivdon.ru/magazine/archive/n2y2023/8183 (In Russ.).
18. Bai, Z., Li, C., Pourzamani, J. et al. Optimizing the resource allocation in cyber physical energy systems based on cloud storage and IoT infrastructure. *J. Cloud. Comp.*, 2024, vol. 13, p. 59. <https://doi.org/10.1186/s13677-024-00615-x>.
19. Ahmad, I., Clark, A., Ali, M. et al. Determining critical nodes in optimal cost attacks on networked infrastructures. *Discov. Internet Things*, 2024, vol. 4, p. 2. <https://doi.org/10.1007/s43926-023-00054-1>.

Статья поступила в редакцию 16.07.2025; одобрена после рецензирования 10.09.2025; принята к публикации 12.09.2025.

The article was submitted 16.07.2025; approved after reviewing 10.09.2025; accepted for publication 12.09.2025.

УДК 629.7.05

МОДЕЛИРОВАНИЕ И АНАЛИЗ ВЛИЯНИЯ ВЕТРОВЫХ ВОЗМУЩАЮЩИХ ВОЗДЕЙСТВИЙ НА ПОЛЕТ МАЛОГО БЕСПИЛОТНОГО ВОЗДУШНОГО СУДНА

Серкин Богдан Анатольевич, Санкт-Петербургский государственный университет аэрокосмического приборостроения, 190000, Российская Федерация, г. Санкт-Петербург, ул. Большая Морская, 67, лит. А,

аспирант, ORCID: 0009-0004-5177-9197, e-mail: bs_serkin@mail.ru

Небылов Александр Владимирович, Санкт-Петербургский государственный университет аэрокосмического приборостроения, 190000, Российская Федерация, г. Санкт-Петербург, ул. Большая Морская, 67, лит. А.

доктор технических наук, профессор, ORCID: 0000-0001-5168-3436, e-mail: nebylov@aanet.ru

Малые беспилотные воздушные суда обладают повышенной чувствительностью к различным ветровым возмущениям из-за низкой скорости полета, малой массы и размеров, что приводит к отклонениям траектории и потере устойчивости, однако существующие исследования часто игнорируют комплексное влияние ветровых воздействий разного типа, что ограничивает эффективность систем управления. Поэтому целью исследования является разработка методики анализа и рекомендаций для компенсации ветровых возмущений для малогабаритных БВС, учитывающих взаимодействие постоянного ветра, турбулентности, сдвига ветра и вихрей от винтов. Для этого используются упрощенные модели вихревых полей, адаптированные для низких скоростей БВС, и моделирование с рассмотрением спектральных моделей турбулентности и низкочастотной фильтрации сигналов управления. Результаты позволяют внедрить данный подход в моделирование систем управления беспилотными воздушными судами для повышения робастности в условиях порывов ветра и турбулентности. Более того, дальнейшие исследования должны быть направлены на учет температурных градиентов и взаимодействия множества БВС в рое.

Ключевые слова: ветровые возмущения, турбулентность, низкочастотная фильтрация, вихревые эффекты, беспилотное воздушное судно

MODELING AND ANALYSIS OF THE EFFECT OF WIND DISTURBANCES ON THE FLIGHT OF A SMALL UAV

Serkin Bogdan A., St. Petersburg State University of Aerospace Instrumentation, 67, lit. A Bolshaya Morskaya St., Saint-Petersburg, 190000, Russian Federation,

graduate student, ORCID: 0009-0004-5177-9197, e-mail: olga@mm.ru

Nebylov Alexander V., St. Petersburg State University of Aerospace Instrumentation, 67, lit. A Bolshaya Morskaya St., Saint-Petersburg, 190000, Russian Federation,

Dr. Sci., Associate Professor, ORCID: 0000-0001-5168-3436, e-mail: nebylov@aanet.ru

Small unmanned aircrafts are highly sensitive to various wind disturbances due to their low flight speed, low mass and size, which leads to trajectory deviations and loss of stability; however, existing studies often ignore the complex influence of wind effects of different types, which limits the effectiveness of control systems. The aim of the study is to develop an analysis methodology and recommendations for wind disturbance compensation for small-sized UAVs, accounting for the interaction of constant wind, turbulence, wind shear and propeller vortices. Simplified models of vortex fields adapted for low speeds of UAVs are used. Modeling with consideration of spectral models of turbulence and low-frequency filtering of control signals has been carried out. The results allow to implement this approach in modeling of unmanned aircraft control systems to improve robustness in conditions of wind gusts and turbulence. Further research should aim to account for temperature gradients and the interaction of multiple UAVs in the swarm.

Keywords: wind disturbances, turbulence, low-frequency filtration, vortex effects, unmanned aircraft

ВВЕДЕНИЕ

Для исследования динамических систем, т. е. систем, обладающих динамическими свойствами, необходимо математически описать систему, линеаризовать нелинейные звенья, математически описать внешние воздействия, формализовать требования к динамике системы, проанализировать и синтезировать систему.

Математическое описание внешних воздействий является таким же важным, как и математическое описание всей системы, поскольку специфика робастных систем проявляется в том, что описываются не непосредственные воздействия, а непараметрические или параметрические классы, которым воздействия должны принадлежать. При этом используют нестатические подходы [1].

БВС имеют свои недостатки по сравнению с большой авиацией. Они обладают меньшей скоростью, взлетным весом, габаритами и высотой полета, что делает их более чувствительными к внешним воздействиям. Атмосферные возмущения усложняют управление и могут угрожать безопасности полета [2, 3]. Влияние ветра на БВС можно рассматривать как передачу энергии, которая

изменяет его полетное состояние [4]. Кроме того, работа БВС в различных условиях местности, высотах и температурах увеличивает подверженность атмосферным возмущениям.

Хотя в улучшение летных характеристик БВС численными, теоретическими или экспериментальными методами внесен определенный вклад [2–4], до сих пор не до конца учитывается влияние возмущений, вызванных ветром. Для снижения риска аварии БВС во время полета и повышения процента успешности миссии крайне важно выяснить, как различные виды воздействия ветра действуют на БВС.

Основные задачи настоящей работы заключаются в систематизации ветровых воздействий для БВС малых размеров с низкой скоростью полета, анализе механизмов влияния различных видов ветровых помех на скорость, ориентацию и положение БВС с последующим моделированием упрощенной модели вихрей, учитывающей малую воздушную скорость БВС и особенности их винтов целью определения рекомендаций по моделированию и управлению с рассмотрением спектральных моделей турбулентности и низкочастотной фильтрации сигналов управления.

ПРИНЦИП ВЛИЯНИЯ ВЕТРА НА БВС

Атмосферные возмущения моделируются через изменения скорости ветра, воздействующие на аэродинамические силы и моменты вращения БВС [5]. Описание с точки зрения скорости является наиболее подходящим способом описания воздействия ветра на БВС. Воздушная скорость V_a определяется как векторная сумма абсолютной скорости БВС V_g и скорости воздушного потока V_f в инерциальной системе координат F_i :

$$V_a = V_g + V_f. \quad (1)$$

Проекция V_a на связанную систему координат БВС F_b :

$$V_a^b = u_a i^b + v_a j^b + w_a k^b = (u_a, v_a, w_a)^T, \quad (2)$$

где u_a, v_a и w_a – компоненты воздушной скорости, спроецированные на оси i^b, j^b, k^b БВС, соответственно.

Справедливо выразить угол атаки α и угол скольжения β как

$$\alpha = \tan^{-1} \left(\frac{w_a}{u_a} \right), \quad (3)$$

$$\beta = \sin^{-1} \left(\frac{v_a}{\sqrt{u_a^2 + v_a^2 + w_a^2}} \right). \quad (4)$$

Ветер влияет на V_a , изменяя α и β , что приводит к сдвигам аэродинамических производных и возмущениям в результирующей силе и моменте БВС. Случайные порывы преимущественно возникают вдоль траектории полета БВС [5]. Это связано с тем, что атмосферные возмущения, воздействующие на судно в продольном направлении, наблюдаются значительно чаще по сравнению с боковыми и вертикальными составляющими. Для неравномерных полей ветра (порывы, вихри) используют усреднение эффективной скорости V_f и ее градиента, а также связь градиента с угловыми скоростями БВС. Формула (1) остается ключевой для описания распределения V_f в пространстве и времени.

При описании с точки зрения передачи энергии влияния ветра на БВС можно рассматривать как передачу кинетической энергии от ветрового поля. Если ее эффективность превышает возможности системы питания и исполнительных механизмов БВС, управление теряется, что создает угрозу безопасности полета [2, 4]. Чем выше скорость ветра, тем больше кинетическая энергия воздуха, что усиливает воздействие. При умеренной энергии ветра БВС сохраняет управляемость за счет соответствующего закона управления.

При малых изменениях высоты вклад потенциальной энергии в кинетическую энергию БВС пренебрежимо мал, что позволяет анализировать влияние ветра через теорию импульса. Предполагая, что на БВС воздействует боковой ветер, масса БВС равна m , эффективная площадь крыла равна S , продольная скорость БВС равна v_{lon} , поперечная скорость равна нулю, а скорость ветра представлена как v_w . Передача импульса между воздушным потоком и БВС происходит за одну секунду. Боковая скорость v_{lat} , вызванная боковым ветром в течение одной секунды, намного меньше скорости самого ветра. Поэтому скорость, вызванную боковым ветром, можно считать одинаковой в течение одной секунды. Согласно закону сохранения импульса и закону сохранения энергии:

$$\begin{cases} v_w^2 S \rho + m v_{lat} = v_w'^2 S \rho + m v_{lat}' \\ \frac{v_w^3 S \rho}{2} + \frac{m v_{lon}^2}{2} = \frac{v_w'^3 S \rho}{2} + \frac{m (v_{lat}'^2 + v_{lon}'^2)}{2}, \end{cases} \quad (5)$$

где плотность воздуха $\rho = 1,29 \text{ кг/м}^3$.

По достижении боковой скорости v'_{lat} можно определить скорость ветра v_w . Исключив из выражения (5) член v'_w , можно получить уравнение 6-й степени со скоростью ветра v_w в качестве неизвестной переменной:

$$(v_w^2 S \rho + m v_{lat} - m v'_{lat})^3 = (v_w^2 S \rho + m^2 v_{lon} - m(v_{lat}^2 + v_{lon}^2))^2. \quad (6)$$

Анализируя влияние массы БВС m и продольной скорости v_{lon} на величину скорости ветра, можно обнаружить, что масса и продольная скорость имеют монотонно возрастающую зависимость от скорости ветра.

ВИДЫ ВОЗДЕЙСТВИЯ ВЕТРА НА БВС

Постоянный ветер – усредненная скорость ветра в заданной среде, используемая как эталон для испытаний БВС. Он не существует в природе, а рассчитывается статистически. Хотя полезен для базового моделирования, он не отражает реальные условия полета, требующие учета других типов ветра.

Турбулентный поток – это непрерывные случайные колебания, сопровождающие постоянный ветер. Возникает из-за сдвига ветра, теплообмена, топографии и вихрей от самолетов. В инженерных расчетах его описывают методами теории стохастических процессов, используя модели Драйдена и фон Кармана [6]. Разница между ними заключается в том, что модель Драйдена задает корреляционную функцию до спектральной плотности, а модель фон Кармана, наоборот, сначала устанавливает спектральную плотность, а затем выводит корреляционную функцию турбулентности. Разница между моделями в крутизне высокочастотной полосы спектра, но для инженерных задач они равноценны.

Спектральная плотность Драйдена:

$$\begin{cases} S_u(\Omega) = \sigma_u^2 \frac{\lambda_u}{\pi} \cdot \frac{1}{1 + (\lambda_u \cdot \Omega)^2}; \\ S_v(\Omega) = \sigma_v^2 \frac{\lambda_v}{\pi} \cdot \frac{1 + 12 \cdot (\lambda_v \cdot \Omega)^2}{(1 + 4 \cdot (\lambda_v \cdot \Omega)^2)^2}; \\ S_w(\Omega) = \sigma_w^2 \frac{\lambda_w}{\pi} \cdot \frac{1 + 12 \cdot (\lambda_w \cdot \Omega)^2}{(1 + 4 \cdot (\lambda_w \cdot \Omega)^2)^2}, \end{cases} \quad (7)$$

где S_u , S_v и S_w – спектральные плотности турбулентного потока вдоль F_b ;

σ_u , σ_v и σ_w – постоянные скорости ветра;

λ_u , λ_v и λ_w – характерные пространственные длины волн турбулентного потока.

Спектральная плотность фон Кармана:

$$\begin{cases} S_u(\Omega) = \sigma_u^2 \frac{\lambda_u}{\pi} \cdot \frac{1}{(1 + (a \cdot \lambda_u \cdot \Omega)^2)^{5/6}}; \\ S_v(\Omega) = \sigma_v^2 \frac{\lambda_v}{\pi} \cdot \frac{1 + (8/3) \cdot (2a \cdot \lambda_v \cdot \Omega)^2}{(1 + 2a \cdot (\lambda_v \cdot \Omega)^2)^{11/6}}; \\ S_w(\Omega) = \sigma_w^2 \frac{\lambda_w}{\pi} \cdot \frac{1 + (8/3) \cdot (2a \cdot \lambda_w \cdot \Omega)^2}{(1 + 2a \cdot (\lambda_w \cdot \Omega)^2)^{11/6}}, \end{cases} \quad (8)$$

где $a = 1,339$.

Для моделирования нестационарной турбулентной составляющей ветра применяется фильтрация белого шума с помощью линейного стационарного фильтра, задаваемого спектром турбулентности фон Кармана [5]. Несмотря на широкое применение данного подхода [7], он имеет ограничение, связанное с отсутствием рациональной передаточной функции. Более удобную аппроксимацию обеспечивают передаточные функции Драйдена, которые приближенно воспроизводят свойства модели фон Кармана. Установившаяся по направлению составляющая ветра и компоненты атмосферных возмущений в уравнениях движения представлены на рисунке 1.

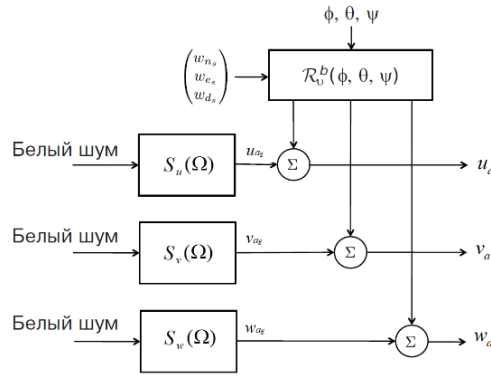


Рисунок 1 – Моделирование постоянного поля ветра с турбулентностью

Здесь R_v^b является матрицей поворота из системы координат БВС в связанную систему координат, Vw_s^i – ветер в окружающей среде, выражаемый в инерциальной системе.

Из-за своей неопределенности влияние турбулентного потока на БВС описывается с помощью силы сопротивления. В гидродинамике сила сопротивления противоположна движению объекта и зависит от свойств среды, формы и скорости:

$$F_D = \frac{1}{2} \rho v^2 C_D S, \tag{9}$$

где F_D – сила сопротивления;

ρ – плотность среды;

v – скорость объекта относительно среды;

S – площадь поперечного сечения;

C_D – безразмерный коэффициент сопротивления.

Для турбулентного потока сила сопротивления в связанной системе координат выражается через спектральную плотность (7) и (8):

$$F_{\text{потока}}^b = \frac{1}{2} \rho C_D S \begin{pmatrix} W_u \cdot S_u \\ W_v \cdot S_v \\ W_w \cdot S_w \end{pmatrix}^2, \tag{10}$$

где W_u , W_v и W_w – три взаимно независимых гауссовских белых шума.

Такой подход позволяет анализировать влияние турбулентности через стохастические силы.

Сдвиг ветра – резкое изменение скорости или направления ветра на малом расстоянии и является сильным атмосферным возмущением [8]. Американский Национальный исследовательский совет (NRC) определяет его как разницу между двумя векторами ветра между двумя точками, деленную на расстояние между ними. Существует множество причин, вызывающих сдвиг ветра. Механизм создания сдвига ветра при нисходящем порыве представлен на рисунке 2.




Рисунок 2 – Сдвиг ветра, возникающий при нисходящем порыве

При полетах БВС распространен низковысотный сдвиг ветра, включающий фронтальный сдвиг ветра [8], ночной реактивный сдвиг ветра [9], сдвиг ветра, вызванный рельефом местности, и микровсплеск [10].

Частота сдвига ветра изменяется с периодом в несколько секунд, что значительно реже по сравнению с турбулентным потоком. При моделировании его имитируют резким изменением скорости ветра. Модели сдвига ветра в зависимости от геометрии профиля делят на прямоугольную модель, трапецевидную модель и модель «1-cosine».

Прямоугольная и трапецевидная модели:

$$V_n = \begin{cases} \frac{y}{d_m} V_{\max} & 0 \leq y \leq d_m; \\ \frac{2d_m - y}{d_m} V_{\max} & d_m \leq y \leq 2d_m, \end{cases} \quad V_r = \begin{cases} \frac{y}{h} V_{\max} & 0 \leq y \leq h; \\ V_{\max} & h \leq y \leq 2d_m - h; \\ \frac{2d_m - y}{d_m} V_{\max} & d_m - h \leq y \leq 2d_m, \end{cases} \quad (11)$$

где V_n и V_r – прямоугольная и трапецевидная модели скорости сдвига ветра с произвольным направлением соответственно;

d_m – длина интервала, в котором существует сдвиг ветра;

V_{\max} – максимальная скорость сдвига ветра.

Полноволновая и полуволновые модели «1-cosine»:

$$V = \begin{cases} 0 & y < 0; \\ \frac{V_{\max}}{2} \left(1 - \cos \frac{\pi y}{d_m}\right) & 0 \leq y \leq 2d_m; \\ 0 & y > 2d_m, \end{cases} \quad V = \begin{cases} 0 & y < 0; \\ \frac{V_{\max}}{2} \left(1 - \cos \frac{\pi y}{d_m}\right) & 0 \leq y \leq d_m; \\ 0 & y > d_m. \end{cases} \quad (12)$$

ВИХРЕВОЙ ПОТОК ВИНТОВ

У БВС, в отличие от крупных самолетов, из-за низкой воздушной скорости основное влияние на следующие за головным судном летательные аппараты оказывают не крыльевые вихри, а вихревое поле, создаваемое вращающимися винтами. При вращении воздух проходит между лопастями, формируя вихревой след, что особенно важно при групповых полетах [11], особенно при полете роём.

Моделирование вихрей основывается на уравнениях Навье-Стокса [12]. Для анализа достаточно учитывать изменяющиеся во времени и пространстве скорости вихрей. Циркуляция (сила вихрей) определяется уравнением:

$$\Gamma = \frac{4r_b g}{\pi r b V}, \quad (13)$$

где g – гравитационная постоянная;

r_b – скорость вращения винтов;

b – диаметр лопасти;

V – относительная скорость потока.

При этом изменением циркуляции вдоль вихревой линии можно пренебречь.

Для небольшого БВС его воздушная скорость V_a намного меньше, чем у пилотируемого самолета, относительная скорость потока V вокруг крыла равна его воздушной скорости V_a , поэтому циркуляция крыльевых вихрей незначительна. Что касается винтовых вихрей, то скорость потока через винты зависит не только от воздушной скорости БВС, но и от скорости вращения винта. В результате винтовые вихри являются основным фактором, влияющим на следование за БВС. Хотя существуют различные модели для представления скоростей, вызванных вихрем, распределения тангенциальных скоростей $V_\theta(r)$ (рис. 3) задаются следующими уравнениями:

Невязкий вихрь

$$V_\theta = \frac{\Gamma}{2\pi r}. \quad (14)$$

Алгебраический вихрь низшего порядка (вихрь Бернхем – Хэллока) [20]

$$V_\theta(r) = \frac{\Gamma}{2\pi r} \frac{r}{r_c^2 + r^2}. \quad (15)$$

Гауссовский вихрь (вихрь Лэмба – Осина)

$$V_\theta(r) = \frac{\Gamma}{2\pi r} \left(1 - \exp\left(-1,256 \times \left(\frac{r}{r_c}\right)^2\right)\right). \quad (16)$$

Модель Проктора [20] для $r > r_c$

$$V_{\theta}(r) = \frac{\Gamma}{2\pi r} \left(1 - \exp \left(-10 \times \left(\frac{r}{b} \right)^{0.75} \right) \right). \quad (17)$$

И для $r \leq r_c$

$$V_{\theta}(r) = \frac{\Gamma}{2\pi r} \left(1 - \exp \left(-10 \times \left(\frac{r}{b} \right)^{0.75} \right) \right) \times \left(1 - \exp \left(-1.2527 \times \left(\frac{r}{r_c} \right)^2 \right) \right). \quad (18)$$




Рисунок 3 – Скорость, вызываемая вихрем

За исключением модели невязкого вихря, каждое уравнение является функцией циркуляции и радиуса r_c , переменная r представляет собой нормальное расстояние до прямой линии вихря. Взаимосвязь между этими переменными видна из рисунке 4, где показаны вертикальные скорости для пяти вышеупомянутых моделей, рассчитанные в предположении, что радиус $r_c = 0.05b$, $\Gamma = 1\text{ м}^2/\text{с}$, и $b = 3$ м. Пики различны, модель Лэмба – Осина дает наибольшее значение, модель Бернхем – Халлока – наименьшее, значения каждой модели имеют тенденцию к согласованию после удвоения длины r_c , хотя и с небольшими различиями.

В большинстве случаев из-за относительной простоты используется невязкая модель, с другой стороны, она может точно описывать реальные вихри, как и другие модели. В то время как при моделировании тесных формаций, таких как полет многороторных БВС, необходимо учитывать пиковую вертикальную скорость вихрей, и в этом случае лучше всего подходят модели Бернхем – Халлока и Лэмба – Осина.




Рисунок 4 – Изменение вертикальной скорости с радиальным расстоянием

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Для моделирования динамики БВС с влиянием различных ветровых полей использовался пакет программных инструментов MATLAB/Simulink R2023a. Крейсерская скорость малого БВС составляет от 13 до 15 м/с [13], а время испытаний – 20 с, поэтому при моделировании влияние ветровых полей на БВС может быть представлено наглядно.

Эталонном состоянии БВС в различных ветровых условиях обозначены синей сплошной линией на рисунках 5–6, включая скорости (u, v, w) в связанной системе координат и углы Эйлера (θ, φ, ψ). Штриховые линии представляют собой движение в возмущенном потоке.

Заданный постоянный ветер в трех направлениях составляет 2 м/с, 2,5 м/с и 3 м/с соответственно (рис. 5) и представлен красной штриховой линией. На рисунке 5 представлен путь в турбулентном потоке желтой штриховой линией.




Рисунок 5 – БВС в пространстве с постоянным ветром и с турбулентным потоком

Из рисунка 5 видно, чтобы БВС оставался стабильным, в угле тангажа происходят некоторые изменения. Кроме того, его курсовой угол также отличается от опорного курсового угла, что является основной причиной отклонения БВС от желаемой траектории. Турбулентный поток не сильно влияет на траекторию, но может вызвать колебания БВС.

На рисунке 6 представлена траектория движения при сдвиге ветра (красная пунктирная линия). Сдвиг ветра добавляется с 11-й по 15-ю секунду, и его значение составляет 7 м/с. На рисунке 6 представлена также траектория движения в вихре винтов (желтая штриховая линия), БВС должен сохранять устойчивость и может оказаться не в состоянии продолжать полет по прямой линии. Как правило, сдвиг ветра имеет большую энергию, и БВС легко выходит из-под контроля.

Скорость, вызванная вихрем, влияет на БВС скорее, как внешний момент. В виду малой скорости ведущего аппарата индуцированная скорость не слишком велика, и БВС может стабилизироваться и избежать падения, что видно из его состояния на рисунке 6. Но полет по желаемой траектории не возможен. Если индуцированная скорость станет больше, возможно, БВС выйдет из-под контроля и упадет на землю.




Рисунок 6 – Полет БВС со сдвигом ветра и в вихре от винтов

Системы управления БВС, как правило, работают в низкочастотном диапазоне (0,1–10 Гц), что обусловлено инерционностью механических компонентов (сервоприводы, двигатели), которые не способны мгновенно реагировать на высокочастотные команды и ограничениями контроллеров, а именно время вычислений и период дискретизации задают верхнюю границу частоты управления, а также динамикой полета: изменения углов Эйлера, скорости и положения происходят плавно, что соответствует низкочастотным сигналам.

Ветровые воздействия, напротив, охватывают более широкий частотный диапазон: турбулентный поток доминирует в диапазоне 1–100 Гц (модели Драйдена и фон Кармана), сдвиг ветра содержит низкочастотные компоненты (0,1–1 Гц) при плавных изменениях и высокочастотные пики (до 50 Гц) при резких порывах, вихри от винтов имеют спектр 5–200 Гц, зависящий от скорости вращения пропеллеров. На рисунке 7 показано сравнение спектров сигналов управления (синий) и ветровых возмущений (красный). Отсюда видно, что пик для управляющих сигналов в диапазоне 0,1–5 Гц (низкие частоты) с резким спадом после 10 Гц, а спектр ветровых возмущений сосредоточен в диапазоне 5–50 Гц с заметными пиками на 10 Гц (турбулентность) и 50 Гц (вихри от винтов).




Рисунок 7 – Спектральная плотность сигналов управления (низкочастотная область) и ветровых возмущений (широкополосный шум)

Низкочастотные компоненты ветра (0,1–2 Гц) наиболее опасны для БВС, так как они совпадают с рабочей полосой системы управления, вызывая резонансные явления, и приводят к накоплению ошибок по положению и ориентации, поэтому для подавления низкочастотных возмущений предложены: адаптивные полосовые фильтры, интеграция данных датчиков (гироскопы, акселерометры) для оценки кинетической энергии ветра и компенсации ее воздействия и модифицированные ПИД-регуляторы с подавлением низких частот (добавление звена с передаточной функцией $H(s) = \frac{s}{s+\alpha}$, где α – частота среза, позволяет ослабить компоненты ниже 1 Гц.

Для демонстрации эффективности фильтрации проведено моделирование полета БВС в условиях сдвига ветра (рис. 8): без фильтра отклонение по курсу достигает 15°, а ошибка положения – 3 м, с адаптивным фильтром – отклонение снижено до 5°, ошибка положения – 0,8 м. График на рисунке 9 демонстрирует зоны перекрытия спектров и преобладание ветровых возмущений на высоких частотах. В зоне перекрытия (0,1–2 Гц) показаны резонансные явления, требующие подавления.




Рисунок 8 – Сравнение траекторий полета без фильтра (красный) и с фильтром (синий)




Рисунок 9 – График наложения спектров

Наложение спектров подчеркивает необходимость применения адаптивных алгоритмов управления, способных подавлять низкочастотные отклонения (сдвиг) и фильтровать высокочастотные вихревые колебания, сохраняя работоспособность БВС в сложных атмосферных условиях.

РЕКОМЕНДАЦИИ ПО МОДЕЛИРОВАНИЮ ПОЛЕТА

Эффективность применения БВС существенно снижается под воздействием ветра, что требует разработки адаптивных и робастных систем управления. Моделирование должно учитывать все

типы ветровых воздействий: постоянный ветер и турбулентность как базовые факторы, сдвиг ветра для особых условий полета, а также винтовые вихри при полете роом.

Постоянный ветер вызывает отклонение от заданной траектории, турбулентность снижает устойчивость, а сдвиг ветра может привести к временной потере управления. Компенсация этих воздействий требует различных подходов: коррекция траектории по данным измерений для постоянного ветра, усовершенствованные алгоритмы управления для турбулентности.

Оптимальная стратегия работы со сдвигом ветра включает его прогнозирование и избегание опасных зон. В критических ситуациях рекомендуется увеличивать кинетическую энергию за счет снижения высоты и угла атаки, а также повышать тягу винтов. Эти меры помогают сохранить устойчивость аппарата при сильных ветровых воздействиях.

ЗАКЛЮЧЕНИЕ

Настоящее исследование демонстрирует существенную уязвимость малогабаритных БВС к ветровым возмущениям, обусловленную их низкой скоростью полета, малым весом и компактными размерами. В работе систематизированы четыре ключевых типа ветровых воздействий (постоянный ветер, турбулентность, сдвиг ветра и винтовые вихри). Особый вклад представляет разработка упрощенных моделей вихревых эффектов от винтов и энергетического подхода к анализу устойчивости, адаптированных именно для малых БВС. Практическая значимость исследования подтверждается результатами моделирования и предложением эффективных решений, включающих комбинацию спектральных моделей с низкочастотной фильтрацией. Внедрение данных подходов позволяет снизить отклонения траектории, повысить устойчивость к возмущениям и оптимизировать энергопотребление. Представленные решения восполняют существующий пробел в исследованиях, где традиционно рассматривались либо отдельные типы возмущений, либо пилотируемые летательные аппараты, предлагая комплексную методологию, специально разработанную с учетом уникальных аэродинамических характеристик малых БВС.

Список источников

1. Raspopov, V. Y. Unmanned Aerospace Vehicle Navigation / V. Y. Raspopov, A. V. Nebylov, S. Sharan, B. Agarwal // *Aerospace Navigation Systems*. – 2016. – P. 321–360. <https://doi.org/10.1002/9781119163060.ch10>.
2. Белоножко, Д. Г. Методика определения вероятности повреждения беспилотных летательных аппаратов в результате воздействия атмосферных факторов внешней среды / Д. Г. Белоножко, И. Д. Королев, Ю. О. Чернышев, Н. Н. Венцов // *Advanced Engineering Research*. – 2022. – № 22 (3). – P. 193–203. <https://doi.org/10.23947/2687-1653-2022-22-3-193-203>.
3. Рябинов, А. В. Моделирование влияния внешних воздействий на процесс автоматизированной посадки БПЛА-квадрокоптера на подвижную платформу с использованием технического зрения / А. В. Рябинов, А. И. Савельев, Д. А. Аникин // *Моделирование и анализ информационных систем*. – 2023. – № 30 (4). – С. 366–381. <https://doi.org/10.18255/1818-1015-2023-4-366-381>.
4. Liu, X. Atmospheric Disturbance Modelling for a Piloted Flight Simulation Study of Airplane Safety Envelope over Complex Terrain / X. Liu, A. Abà, P. Capone, L. Manfredi, Y. Fu *Aerospace*. – 2022. – Vol. 9 (2). – P. 103. <https://doi.org/10.3390/aerospace9020103>.
5. Биард, Р. У. Малые беспилотные летательные аппараты: теория и практика / Р. У. Биард, Т. У. Мак-Лэйн. – Москва : ТЕХНОСФЕРА, 2015. – 312 с.
6. Шелехов, А. П. Использование малоразмерных БПЛА для измерения турбулентности в атмосфере / А. П. Шелехов, А. Л. Афанасьев, Е. А. Шелехова, А. А. Кобзев, А. Е. Тельминов, А. Н. Молчунов, О. Н. Поплевина // *Изв. РАН. Физика атмосферы и океана*. – 2021. – Т. 57, № 5. – С. 611–624. <https://doi.org/10.31857/S0002351521050138>.
7. Nelson, R. C. *Flight Stability and Automatic Control* / R. C. Nelson. – 2nd ed. – 1998.
8. Rautenberg, A. Calibration Procedure and Accuracy of Wind and Turbulence Measurements with Five-Hole Probes on Fixed-Wing Unmanned Aircraft in the Atmospheric Boundary Layer and Wind Turbine Wakes / A. Rautenberg, J. Allgeier, S. Jung, J. Bange // *Atmosphere*. – 2019. – Vol. 10 (3). – P. 124. <https://doi.org/10.3390/atmos10030124>.
9. Palomaki, R. T. Wind Estimation in the Lower Atmosphere Using Multirotor Aircraft / R. T. Palomaki, N. T. Rose, M. van den Bossche, T. J. Sherman, and S. F. J. De Wekker. // *J. Atmos. Oceanic Technol.* – 2017. – Vol. 34. – P. 1183–1191. <https://doi.org/10.1175/JTECH-D-16-0177.1>.
10. Yang, Y. A Study of Wind Shear Influences on the Aerodynamic Performances of a UAV Airfoil / Y. Yang, D. Liu, L. Lu // *Applied Sciences*. – 2023. – Vol. 13 (6). – P. 3764. <https://doi.org/10.3390/app13063764>.
11. Karimian, A. On the Propeller Tip Vortex Characteristics and its Interaction Noise / A. Karimian, S. Palani, C. Paruchuri, P. Joseph // *AIAA AVIATION Forum*. – 2023. <https://doi.org/10.2514/6.2023-3655>.
12. Guangsong, Yuan. A continuous modeling method via improved pigeon-inspired optimization for wake vortices in UAVs close formation flight / Guangsong Yuan, Jie Xia, Haibin Duan // *Aerospace Science and Technology*. – 2022. – Vol. 120. – P. 107259. <https://doi.org/10.1016/j.ast.2021.107259>.
13. Серкин, Б. А. Модернизация беспилотного летательного аппарата самолетного типа для обеспечения вертикального взлета и посадки / Б. А. Серкин // *Известия высших учебных заведений. Приборостроение*. – 2025. – № 68 (1). – С. 50–55. <https://doi.org/10.17586/0021-3454-2025-68-1-50-55>.

References

1. Raspopov, V. Y., Nebylov, A. V., Sharan, S., Agarwal, B. Unmanned Aerospace Vehicle Navigation. *Aerospace Navigation Systems*, 2016, pp. 321–360. <https://doi.org/10.1002/9781119163060.ch10>.
2. Belonozhko, D. G., Korolev, I. D., Chernyshev, Yu. O., Ventsov, N. N. Methodology for Determining the Probability of Damage to UAV as a Result of Exposure to Atmospheric Environmental Factors. *Advanced Engineering Research*, 2022, no. 22 (3), pp. 193–203. <https://doi.org/10.23947/2687-1653-2022-22-3-193-203> (In Russ.).
3. Ryabinov, A. V., Saveliev, A. I., Anikin, D. A. Modeling the influence of external influences on the process of automated landing of a UAV-quadcopter on a moving platform using technical vision. *Modeling and Analysis of Information Systems*, 2023, no. 30 (4), pp. 366–381. <https://doi.org/10.18255/1818-1015-2023-4-366-381> (In Russ.).
4. Liu, X., Abà, A., Capone, P., Manfredi, L., Fu, Y. Atmospheric Disturbance Modelling for a Piloted Flight Simulation Study of Airplane Safety Envelope over Complex Terrain. *Aerospace*, 2022, vol. 9 (2), p. 103. <https://doi.org/10.3390/aerospace9020103>.
5. Beard, R. U., McLain, T. W. *Small Unmanned Aircraft Theory and Practice*. Moscow, Technosphere Publ., 2015. 312 p. (In Russ.).
6. Shelekhov, A. P., Afanasiev, A. L., Kobzev, A. A., Shelekhova, E. A., Telminov, A. E., Molchunov, A. N., Poplevina, O. N. Use of Small-Size UAVs for Turbulence Measurements in the Atmosphere. *Izvestiya. Atmospheric and Oceanic Physics*, 2021, vol. 57, no. 5, pp. 611–624. <https://doi.org/10.31857/S0002351521050138> (In Russ.).
7. Nelson, R. C. *Flight Stability and Automatic Control*. 2nd ed. 1998.
8. Rautenberg, A., Allgeier, J., Jung, S., Bange, J. Calibration Procedure and Accuracy of Wind and Turbulence Measurements with Five-Hole Probes on Fixed-Wing Unmanned Aircraft in the Atmospheric Boundary Layer and Wind Turbine Wakes. *Atmosphere*, 2019, vol. 10 (3), p. 124. <https://doi.org/10.3390/atmos10030124>.
9. Palomaki, R. T., N. T. Rose, M. van den Bossche, T. J. Sherman, and S. F. J. De Wekker. Wind Estimation in the Lower Atmosphere Using Multirotor Aircraft. *J. Atmos. Oceanic Technol.*, 2017, vol. 34, pp. 1183–1191. <https://doi.org/10.1175/JTECH-D-16-0177.1>.
10. Yang, Y., Liu, D., Lu, L. A Study of Wind Shear Influences on the Aerodynamic Performances of a UAV Airfoil. *Applied Sciences*, 2023, vol. 13 (6), p. 3764. <https://doi.org/10.3390/app13063764>.
11. Karimian, A., Palani, S., Paruchuri, C., Joseph, P. On the Propeller Tip Vortex Characteristics and its Interaction Noise. *ALAA AVIATION Forum*, 2023. <https://doi.org/10.2514/6.2023-3655>.
12. Guangsong, Yuan, Jie, Xia, Haibin, Duan, A continuous modeling method via improved pigeon-inspired optimization for wake vortices in UAVs close formation flight. *Aerospace Science and Technology*, 2022, vol. 120, p. 107259. <https://doi.org/10.1016/j.ast.2021.107259>.
13. Serkin, B. A. Modernization of an aircraft-type UAV to ensure vertical takeoff and landing. *Journal of Instrument Engineering*, 2025, no. 68 (1), pp. 50–55. <https://doi.org/10.17586/0021-3454-2025-68-1-50-55> (In Russ.).

Статья поступила в редакцию 12.05.2025; одобрена после рецензирования 21.07.2025; принята к публикации 24.07.2025.

The article was submitted 12.05.2025; approved after reviewing 21.07.2025; accepted for publication 24.07.2025.

ПРАВИЛА ДЛЯ АВТОРОВ

1. В журнале публикуются материалы на английском и русском языках по тематике, соответствующей утвержденным для журнала отраслям наук, группам специальностей.

2. В список соавторов работ включаются только те лица, которые внесли творческий вклад в подготовку представленных материалов. Лицам, оказавшим только техническую помощь, можно выразить благодарность в конце статьи. Один человек может быть автором (соавтором) не более чем двух статей в одном номере журнала, причем единственным автором он может быть только в одной статье.

3. Объем публикаций для научных статей должен быть не менее 8 страниц, а количество источников в библиографическом списке (списке литературы) – не менее 10 позиций.

4. Содержание каждой статьи должно включать следующие элементы: УДК; название статьи; сведения об авторах, включая их место работы, должность, адрес электронной почты; аннотацию объемом от 100 до 250 слов, ключевые слова (от 9 до 13); графическую аннотацию, отражающую содержание статьи; название статьи, сведения об авторах, аннотацию и ключевые слова на английском языке (для англоязычных статей – на русском языке); введение – оно должно заканчиваться формулировкой цели работы в явной форме; собственно текст статьи – очень желательна его сегментация на разделы, имеющие содержательные заголовки; выводы или заключение (должны соответствовать формулировке цели статьи).

5. Для русскоязычных статей приводится два библиографических списка: на языке оригинала статьи; список с транслитерацией русскоязычных источников на латиницу и (дополнительно) приведением в квадратных скобках переводов названий статей и названий источников на английский язык.

В «русскоязычном» библиографическом списке (списке литературы) порядок следования источников – по алфавиту фамилий авторов (сначала русскоязычные источники, потом иноязычные). На все источники, включенные в библиографический список, должны быть даны ссылки в тексте статьи в квадратных скобках. При необходимости авторы могут указывать номера страниц в источниках, на которые даются ссылки. Приветствуются ссылки на иноязычные источники, а также на материалы, опубликованные ранее в журнале «Прикаспийский журнал: управление и высокие технологии». Однако в последнем случае количество таких ссылок не должно превышать 20 % от общего количества источников, включенных в библиографический список. Для источников, имеющих DOI, целесообразно его указывать. При ссылках на статьи, опубликованные в журнале «Прикаспийский журнал: управление и высокие технологии», целесообразно в конце библиографического описания источника в круглых скобках указывать гиперссылку, указывающую на место размещения статьи на страничке сайта Астраханского государственного университета.

Ссылки в библиографическом списке на материалы, размещенные в интернете, допускаются при соблюдении следующих условий: если у материала, на который дается ссылка, имеется автор и/или название, то они должны быть указаны для этого источника; должен быть приведен полный маршрут доступа к источнику в интернете; должна быть указана дата обращения (доступа) к источнику.

Ограничения по списку литературы: доля самоцитирований для любого из авторов статьи, а также по совокупности всех авторов статьи, не должна превышать 25 %; доля ссылок на статьи с участием одного автора, не являющегося автором (соавтором) статьи, не должна превышать 25 %.

6. Суммарная доля таблиц и иллюстраций в общем объеме представляемой статьи не должна превышать 40 %. Под иллюстрациями понимаются следующие объекты: диаграммы; графики; рисунки; эскизы; фотографии; карты и т.п.

7. Доля оригинального текста в статьях (оцениваемого через систему «Антиплагиат» на сайте www.antiplagiat.ru) должна быть не менее 80 %.

8. Указание на то, что работа финансируется по какому-либо гранту, в рамках Федеральной целевой программы, государственного заказа и пр. дается в виде постраничной сноски после заголовка (названия) работы.

9. В сведения об авторах работ помимо места работы и должности целесообразно включать ORCID автора и гиперссылку на страничку с его личными наукометрическими показателями на сайте www.elibrary.ru. По желанию можно привести также ссылки на странички с наукометрическими показателями на Scopus, в ResearchGate; на личную страничку, размещенную на сайте организации.

10. Основные технические требования к оформлению статей (материалов):

10.1. Текст должен быть расположен по ширине страницы формата А4 с учётом полей (все поля по 2,5 см), набран шрифтом Times New Roman, кегль 12, межстрочный интервал 1,0. В таблицах, подрисовочных надписях допускается уменьшенный шрифт – вплоть до 10 кегля. Альбомная ориентация страниц допускается только в порядке исключения для следующих случаев: широкоформатные таблицы с большим количеством колонок; иллюстрации большого размера, которые не умещаются на странице с книжной ориентацией.

Абзацные отступы одинаковы по всему тексту – 0,75 см. Кавычки («»), скобки ([], ()), маркеры и другие знаки должны быть аналогичными на протяжении всего предоставляемого для публикации материала.

ПРИКАСПИЙСКИЙ ЖУРНАЛ: управление и высокие технологии

НАУЧНО-ТЕХНИЧЕСКИЙ ЖУРНАЛ

**2025
№ 3 (71)**

Свидетельство о регистрации средства массовой информации
Федеральной службы по надзору в сфере массовых коммуникаций,
связи и охраны культурного наследия
ПИ № ФС77-31932 от 16 мая 2008 г.

Учредитель

Астраханский государственный университет имени В. Н. Татищева
Российская Федерация, 414056, г. Астрахань, ул. Татищева, 20а

Адрес редакции:

Российская Федерация, 414056, г. Астрахань, ул. Татищева, 20

Адрес издателя:

Российская Федерация, 414056, г. Астрахань, ул. Татищева, 20а

Главный редактор А. М. Лихтер

Редактирование,

компьютерная правка, верстка *Н. Н. Сахно*

Дата выхода в свет 27.01.2026 г.

Цена свободная

Уч.-изд. 12,7. Усл. печ. л. 17,7.

Заказ № 4723. Тираж 500 экз. (первый завод – 23 экз.)

Астраханский государственный университет имени В. Н. Татищева
414056, г. Астрахань, ул. Татищева, 20а
тел. (8512) 24-66-60 (доб. 3; издательско-полиграфический отдел)
Отпечатано в Астраханской цифровой типографии
414040, г. Астрахань, пл. К. Маркса, 33
тел./факс (8512) 54-00-11, 73-40-40,
E-mail: a-d-t@mail.ru