

ISSN 2686-679X

ВЕСТНИК РГГУ

Серия
«Информатика.
Информационная безопасность.
Математика»

Научный журнал

RSUH/RGGU BULLETIN

“Information Science.
Information Security. Mathematics”
Series

Academic Journal

Основан в 2018 г.
Founded in 2018

1
2026

VESTNIK RGGU. Seriya "Informatica. Informacionnaya bezopasnost. Matematika"

RSUH/RGGU BULLETIN. "Information Science. Information Security. Mathematics" Series
Academic Journal

There are 4 issues of the printed version of the journal a year.

Founder and Publisher

Russian State University for the Humanities (RSUH)

RSUH/RGGU BULLETIN. "Information Science. Information Security. Mathematics" series is included: in the Russian Science Citation Index; in the List of leading scientific magazines journals and other editions for publishing PhD research findings peer-reviewed publications fall within the following research area:

1.1.6. Computational Mathematics (physical and mathematical sciences)

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

2.3.8. Informatics and information processes (technical science)

Objectives and areas of research

RSUH/RGGU BULLETIN. "Information Science. Information Security. Mathematics" series publishes the results of research by scientists from RSUH and other universities and other Russian and foreign academic institutions. The areas covered by contributions include theoretical and applied computer science, up-to-date IT, means and technologies of information protection and information security as well as the issues of theoretical and applied mathematics including analytical and imitation models of different processes and objects. Special emphasis is put on articles and reviews covering research in indicated directions in the areas of social and humanitarian problems and also issues of personnel training for these directions.

RSUH/RGGU BULLETIN. "Information Science. Information Security. Mathematics" series is registered by Federal Service for Supervision of Communications Information Technology and Mass Media. 25.05.2018, reg. No. FS77-72977

Editorial staff office: bldg. 6, bld. 6, Miuskaya sq., Moscow, Russia, 125047

e-mail: grnat@rambler.ru

ВЕСТНИК РГГУ. Серия «Информатика. Информационная безопасность. Математика»
Научный журнал

Выходит 4 номера печатной версии журнала в год.

Учредитель и издатель – Российский государственный гуманитарный университет (РГГУ)

ВЕСТНИК РГГУ, серия «Информатика. Информационная безопасность. Математика», включен: в систему Российского индекса научного цитирования (РИНЦ); в Перечень рецензируемых научных изданий, в которых должны быть опубликованы основные результаты диссертаций на соискание ученой степени кандидата наук, на соискание ученой степени доктора наук по следующим научным специальностям и соответствующим им отраслям науки:

1.1.6. Вычислительная математика (физико-математические науки)

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

2.3.8. Информатика и информационные процессы (технические науки)

Цели и область

В журнале «Вестник РГГУ», серия «Информатика. Информационная безопасность. Математика», публикуются результаты научных исследований ученых и специалистов РГГУ, а также других университетов и научных учреждений России и зарубежных стран. Направления публикаций включают теоретическую и прикладную информатику, современные информационные технологии, методы, средства и технологии защиты информации и обеспечения информационной безопасности, а также проблемы теоретической и прикладной математики, включая разработку аналитических и имитационных моделей процессов и объектов различной природы. Особое внимание уделяется статьям и обзорам, посвященным исследованиям по указанным направлениям в области социальных и гуманитарных проблем, а также вопросам подготовки кадров по соответствующим специальностям для данных направлений.

ВЕСТНИК РГГУ. Серия «Информатика. Информационная безопасность. Математика», зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций 25.05.2018 г., регистрационный номер ПИ № ФС77-72977.

Адрес редакции: 125047, г. Москва, вн. тер. г. муниципальный округ Тверской, Миусская пл., д. 6, стр. 6

Электронный адрес: gnat@rambler.ru

Founder and Publisher

Russian State University for the Humanities (RSUH)

Editor-in-chief

E.N. Nadezhdin, Dr. of Sci. (Engineering), professor, Russian State University for the Humanities (RSUH), Moscow, Russian Federation

Editorial Board

V.I. Korolev, Dr. of Sci. (Engineering), professor, The Institute of Informatics Problems of the Russian Academy of Sciences (IPI RAN), Moscow, Russian Federation (*deputy editor-in-chief*)

N.V. Grishina, Cand. of Sci. (Engineering), associate professor, Russian State University for the Humanities (RSUH), Moscow, Russian Federation (*executive secretary*)

L.A. Aslanyan, Dr. of Sci. (Physics and Mathematics), professor, corresponding member, Nacional Academy of Sciences of the Republic of Armenia, Institute for Informatics and Automation Problems of the National Academy of Sciences of the Republic of Armenia, Yerevan, Republic of Armenia

S.N. Baibekov, Dr. of Sci. (Engineering), professor, Kazakh University of Technology and Business, Astana, Republic of Kazakhstan

S.B. Veprev, Dr. of Sci. (Engineering), professor, Russian Presidential Academy of National Economy and Public Administration, Moscow, Russian Federation

G.S. Ivanova, Dr. of Sci. (Engineering), professor, Bauman Moscow State Technical University, Moscow, Russian Federation

V.M. Maximov, Dr. of Sci. (Physics and Mathematics), professor, Russian State University for the Humanities (RSUH), Moscow, Russian Federation

R.S. Motul'skii, Dr. of Sci. (Pedagogics), professor, Institute of Modern Knowledge, Minsk, Republic of Belarus

Yu.I. Ozhigov, Dr. of Sci. (Physics and Mathematics), professor, Lomonosov Moscow State University, Moscow, Russian Federation

S.M. Sokolov, Dr. of Sci. (Physics and Mathematics), professor, Keldysh Institute of Applied Mathematics, Moscow, Russian Federation

V.A. Tsvetkova, Dr. of Sci. (Engineering), professor, Library for Natural Sciences of the RAS, Moscow, Russian Federation

Executive editor:

N.V. Grishina, Cand. of Sci. (Engineering), associate professor,
Russian State University for the Humanities (RSUH)

Учредитель и издатель

Российский государственный гуманитарный университет (РГГУ)

Главный редактор

Е.Н. Надеждин, доктор технических наук, профессор, Российский государственный гуманитарный университет (РГГУ), Москва, Российская Федерация

Редакционная коллегия

В.И. Королев, доктор технических наук, профессор, ФГУ «Федеральный исследовательский центр «Информатика и управление» РАН, Москва, Российская Федерация (*заместитель главного редактора*)

Н.В. Гришина, кандидат технических наук, доцент, Российский государственный гуманитарный университет (РГГУ), Москва, Российская Федерация (*ответственный секретарь*)

Л.А. Асланян, доктор физико-математических наук, профессор, член-корреспондент Национальной академии наук Республики Армения, Институт проблем информатики и автоматизации НАН Республики Армения, Ереван, Республика Армения

С.Н. Байбеков, доктор технических наук, профессор, Казахский университет технологии и бизнеса, Астана, Республика Казахстан

С.Б. Вепрев, доктор технических наук, профессор, Российская академия народного хозяйства и государственной службы при Президенте Российской Федерации (РАНХиГС), Москва, Российская Федерация

Г.С. Иванова, доктор технических наук, профессор, Московский государственный технический университет им. Н.Э. Баумана, Москва, Российская Федерация

В.М. Максимов, доктор физико-математических наук, профессор, Российский государственный гуманитарный университет (РГГУ), Москва, Российская Федерация

Р.С. Мотульский, доктор педагогических наук, профессор, Институт современных знаний, Минск, Республика Беларусь

Ю.И. Ожигов, доктор физико-математических наук, профессор, Московский государственный университет им. М.В. Ломоносова (МГУ), Москва, Российская Федерация

С.М. Соколов, доктор физико-математических наук, профессор, Институт прикладной математики им. М.В. Келдыша РАН, Москва, Российская Федерация

В.А. Цветкова, доктор технических наук, профессор, Библиотека по естественным наукам РАН, Москва, Российская Федерация

Ответственный за выпуск:

Н.В. Гришина, кандидат технических наук, доцент,
Российский государственный гуманитарный университет (РГГУ)

CONTENTS

Information Science

<i>Aleksandr V. Vinokurov</i> Formalized formulation of the problem of detecting an attacker's information and technical influence on ground-based robotic systems	8
<i>Darya V. Dorogan, Valeria S. Sikidina, Dzhakhed Rakhmani</i> Comparative analysis of machine learning methods in the industrial Internet of Things at oil refining production	19
<i>Anna B. Klimenko, Vadim V. Zhepan</i> Analysis of Python libraries for solving optimization problems in student applied research	35
<i>Nikita A. Kotlyarov, Kirill L. Tassov</i> Development of a method for classification and temporal localization of trains based on neural networks	55
<i>Andrei P. Titov, Natalia V. Grishina, Darya N. Titova</i> The concept of a local photo gallery organizer based on recognition with multifactorial face filtering	71

СОДЕРЖАНИЕ

Информатика

<i>Александр В. Винокуров</i> Формализованная постановка задачи обнаружения информационно-технических воздействий злоумышленника на наземные робототехнические комплексы	8
<i>Дарья В. Дорогань, Валерия С. Сикидина, Джахед Рахмани</i> Сравнительный анализ методов машинного обучения в промышленном интернете вещей на нефтеперерабатывающем производстве	19
<i>Анна Б. Клименко, Вадим В. Жепан</i> Анализ библиотек языка PYTHON для решения задач оптимизации в студенческих прикладных исследованиях	35
<i>Никита А. Котляров, Кирилл Л. Тассов</i> Разработка метода классификации и временной локализации поезда на основе нейронных сетей	55
<i>Андрей П. Титов, Наталия В. Гришина, Дарья Н. Титова</i> Концепция локального органайзера фотогалереи на основе распознавания с многофакторной фильтрацией лиц	71

Формализованная постановка задачи обнаружения информационно-технических воздействий злоумышленника на наземные робототехнические комплексы

Александр В. Винокуров

*Российский государственный гуманитарный университет,
Москва, Россия, VAV73@rambler.ru*

Аннотация. Статья посвящена решению задачи защиты информации и функциональной устойчивости наземных робототехнических комплексов (НРТК). Так как робототехнические комплексы (РТК) разрабатываются и применяются для достижения целей функционирования надсистем, то уровень эффективности их применения будет зависеть от защищенности информации от деструктивных воздействий. На основе анализа условий функционирования и структуры НРТК предлагается формализованная постановка научной задачи и вариант ее решения путем разработки методики обнаружения информационно-технических воздействий (ИТВ) на системы НРТК, что определяет цель статьи. В качестве критерия оптимальности предлагается выбрать минимизацию вероятности пропуска ИТВ при ограничении на вероятность ложного реагирования подсистемы обнаружения ИТВ при их отсутствии. Построена функциональная модель процесса обнаружения ИТВ на системы НРТК, отличительными признаками которой является дополнительный контур прохождения внутренней информации о состоянии контролируемых систем (элементов) НРТК, в том числе системы защиты информации. На основании концептуального подхода и функционального моделирования разработана методика обнаружения ИТВ на системы НРТК. Особенности искусственных иммунных систем (ИИС), такие как динамическое дообучение и гибкая масштабируемость, обеспечивают оперативную генерацию новых знаний об угрозах, что определило их принципиальную возможность применения как базовой технологии для обнаружения ИТВ.

Ключевые слова: информационно-технические воздействия, наземный робототехнический комплекс, угрозы безопасности информации

Для цитирования: Винокуров А.В. Формализованная постановка задачи обнаружения информационно-технических воздействий злоумышленника на наземные робототехнические комплексы // Вестник РГГУ. Серия «Информатика. Информационная безопасность. Математика». 2026. № 1. С. 8–18. DOI: 10.28995/2686-679X-2026-1-8-18

Formalized formulation of the problem of detecting an attacker's information and technical influence on ground-based robotic systems

Aleksandr V. Vinokurov

*Russian State University for the Humanities, Moscow, Russia,
VAV73@rambler.ru*

Abstract. The article is devoted to solving the problem of information security and functional stability of ground-based robotic complexes (NRTC). Since robotic complexes (RTCs) are being developed and used to achieve the goals of operating supersystems, the level of effectiveness of their use will depend on the protection of information from destructive influences. Based on the analysis of the operating conditions and structure of the NRTC, a formalized formulation of the scientific problem and a variant of its solution are proposed by developing a methodology for detecting information technology impacts (ITV) on the NRTC systems, which determines the purpose of the article. As an optimality criterion, it is proposed to choose minimizing the probability of missing ITV while limiting the probability of a false response by the ITV detection subsystem in their absence. A functional model of the ITV detection process for NRTC systems has been constructed, the distinctive features of which are an additional loop for passing internal information about the state of controlled NRTC systems (elements), including information security systems. Based on the conceptual approach and functional modeling, a technique for detecting ITV on NRTC systems has been developed. The features of artificial immune systems (AIS), such as dynamic retraining and flexible scalability, ensure the rapid generation of new knowledge about threats, which has determined their fundamental application as a basic technology for detecting ITV.

Keywords: information and technical impacts, ground-based robotic systems, and information security threats

For citation: Vinokurov, A.V. (2026), “Formalized formulation of the problem of detecting an attacker's information and technical influence on ground-based robotic systems”, *RSUH/RGGU Bulletin. “Information Science. Information Security. Mathematics” Series*, no. 1, pp. 8–18, DOI: 10.28995/2686-679X-2026-1-8-18

Разработка и внедрение технологий робототехники является одним из приоритетных направлений создания новых и модернизации существующих вооружений образцов вооружения и военной техники. В настоящее время практически во всех современных вооруженных конфликтах применяются робототехнические комплексы (РТК) [Иванов 2016].

Наземный робототехнический комплекс (НРТК) – совокупность функционально связанных одного или нескольких роботов, их рабочих органов, средств эксплуатации и оборудования, обеспечивающего их техническую эксплуатацию и применение для выполнения задач по назначению в наземной среде.

Одним из требований, предъявляемых к НРТК, является сохранение работоспособности и возможности их применения в любое время суток и метеорологических условиях в условиях радиоэлектронного и информационного противодействия, а также в условиях внешних воздействующих факторов. Если рассматривать НРТК как информационную систему, то обеспечение их информационной безопасности может быть достигнуто лишь при комплексном решении трех составляющих проблемы [Малюк 2004]:

- защита циркулирующей в НРТК информации от ИТВ;
- защита систем и элементов НРТК от ИТВ;
- защита надсистемы, в интересах которой функционирует НРТК, от угроз со стороны РТК.

Третья составляющая отражает свойство РТК как элемента техносферы и при определенных негативных воздействиях на них могут угрожать ее безопасности. Техносферная безопасность как защищенность техносферы от стихийных бедствий, техногенных аварий, катастроф, пожаров и негативных антропогенных воздействий (терроризма, ошибок) взаимосвязана с общей проблемой информационной безопасности [Кузнецов 2018, с. 107].

Структура и состав современных НРТК с точки зрения обеспечения их информационной безопасности [Лисицын 2020, с. 342] определяют следующие факторы:

- применение элементной базы и программного обеспечения зарубежного производства допускает возможность злоумышленнику осуществлять ИТВ на системы НРТК;
- большое число устройств, в том числе использующих технологии искусственного интеллекта, входящих в состав НРТК, имеют потенциальные уязвимости в протоколах взаимодействия, что позволяет злоумышленнику использовать такие устройства для дистанционного проникновения в НРТК;

- большие объемы разнородных данных, обрабатываемых системами и устройствами НРТК, усложняет и замедляет процесс анализа уязвимостей;
- ограничения на ресурсы, выделяемые на решение задач защиты информации, определяющими из которых являются вычислительные, массогабаритные и энергетические ограничения, не позволяют существенно усложнить систему защиты информации и обнаружения ИТВ.

Данные факторы обосновывают необходимость решения задач не только по защите информации, циркулирующей в радиоканалах НРТК, но и по оперативному выявлению угроз и обнаружению ИТВ злоумышленника на системы НРТК и принятию мер по ликвидации их последствий.

Соответственно возникает необходимость совершенствования системы защиты информации, передаваемой по радиоканалам НРТК, путем добавления функциональных возможностей обнаружения ИТВ злоумышленника при минимальном и обоснованном отвлечении ограниченных ресурсов, которое не должно приводить к снижению их функциональной эффективности. Таким образом, в рассматриваемой предметной области существует противоречие, заключающееся в том, что, с одной стороны, необходимо обеспечить устойчивое и безопасное функционирование НРТК в условиях ИТВ злоумышленника, а с другой стороны, особенности структуры и автономность их функционирования не позволяют реализовать существующие методики обнаружения ИТВ злоумышленнику.

С учетом величины потенциального ущерба при реализации злоумышленнику ИТВ сформулируем общую задачу защиты информации и функциональной устойчивости НРТК в виде оптимизационной задачи:

$$\left\{ \begin{array}{l} X(u^*(V, R), Y(V, R) \rightarrow \min_{u \in U(V, R)} \\ t(v_i) \leq t(v_i)_{\text{доп}} \\ t(r_j) \leq t(r_j)_{\text{доп}} \\ P_1 \leq P_{1\text{доп}} \end{array} \right. , \quad (1)$$

где: X – множество значений показателей эффективности системы защиты информации и обнаружения ИТВ;

$V = \{v_i, i = 1, \dots, 4\}$ – вид информации в НРТК (V_1 – навигационная, V_2 – телеметрическая; V_3 – командно-программная, V_4 – специальная);

$R = (r_1, r_2, \dots, r_j)$ – вектор контролируемых подсистем (элементов) НРТК;

$Y(V, R) = \{y_z(v_i, r_j), z = 1, \dots, Z\}$ – множество стратегий злоумышленника по ИТВ на подсистемы (элементы) и защищаемую информацию в НРТК, направленные на нарушение защищенности информации (целостности и доступности), которая может быть оценена показателями: $P_{\text{нав}}$ – вероятность навязывания ложной информации, $P_{\text{тр}}$ – вероятность трансформации информации;

$U(V, R) = f(S, C, t_d, t(v), t(r))$ – стратегии по обнаружению ИТВ злоумышленника и их локализации (противодействию), где:

$u(v_i)$ – стратегии по обнаружению ИТВ на информацию i -го вида и их локализации (противодействию);

$u(r_j)$ – стратегии по обнаружению ИТВ на j -й элемент НРТК и их локализации (противодействию);

$u^*(V, R)$ – оптимальная стратегия по обнаружению ИТВ на информацию, циркулирующую в НРТК, и системы (элементы) НРТК, которая минимизирует вероятность необнаружения (пропуска) ИТВ $P_{\text{необ.ИТВ}}$ (ошибки 2-го рода);

$S = (s_1, s_2, \dots, s_z)$ – вектор состояний системы защиты информации (СЗИ);

$C = (c_1, c_2, \dots, c_w)$ – вектор реакций на ИТВ НРТК;

$t = (t_{\text{обн}} + t_p)$ – время идентификации ИТВ, включающее время на обнаружение ИТВ $t_{\text{обн}}$ и время реакции t_p ;

$t(v_i)$ – время идентификация ИТВ на V информацию i -го вида;

$t(r_j)$ – время идентификации ИТВ на j -е элементы НРТК;

P_1 – вероятность ложной реакции при отсутствии ИТВ;

$t(r_j)_{\text{доп}}$ – допустимое время идентификация ИТВ на j -е элементы РТС ВН до выполнения функциональной задачи соответствующей системой РТК;

$t(v_i)_{\text{доп}}$ – допустимое время идентификации ИТВ на V информацию i -го вида до ее доведения до потребителя (ЛПР);

$P_{1\text{доп}}$ – допустимая вероятность ложной реакции при отсутствии ИТВ (ошибки 1-го рода) (параметр, задаваемый в тактико-техническом задании при проектировании системы защиты информации, с учетом функциональных возможностей НРТК).

Поставленная задача (1) решается при следующих ограничениях:

$$y_k(v_i) \in Y(V, R), C(u^*(V, R)) \leq C_{\text{доп}}; X(u^*(V, R)) \leq L.$$

Таковыми ресурсами $C_{\text{доп}}$ и ограничениями L выступают:

- количество персонала, осуществляющего управление НРТК и обработку СИ;
- массогабаритные параметры НРТК и СЗИ;
- вычислительные мощности НРТК;
- временные ограничения на принятие решений по управлению НРТК и целевой нагрузкой (ЦН);
- неисправности и отказы технических систем НРТК.

Класс и вид НРТК, а также функциональные задачи, решаемые ими, и показатели оценки эффективности их функционирования принципиального значения для решения задачи (1) не имеют и в дальнейшем не рассматриваются.

Условия функционирования НРТК и нестационарность состояния радиоканала обосновывают выбор концепции адаптивной оптимизации как обеспечивающей принятие последовательности решений с учетом изменения ситуации. Условию сформулированной задачи улучшения одних показателей при условии неухудшения других соответствует критерий Парето:

$$u = u^* \Leftrightarrow \forall K_i(u^*) \geq K_i(u_i), \exists K_j(u^*) > K_j(u_j). \quad (3)$$

Предлагаемый подход на основе концепции адаптивной оптимизации позволяет использовать ресурсы НРТК, выделяемые на цели защиты информации, адаптивно решаемым им задачам в условиях ИТВ и сформулировать гипотезу о возможности построения интегрированной системы защиты информации и обнаружения ИТВ S^* , в которой при ухудшении в допустимых пределах отдельных показателей качества информации в целом обеспечивается ее защищенность и не ухудшается целевая функция НРТК, т. е. такой, что

$$\exists y \in Y: K(S^*, y) \geq K(S, y). \quad (4)$$

На рис. 1 представлена функциональная модель процесса обнаружения ИТВ на системы НРТК.

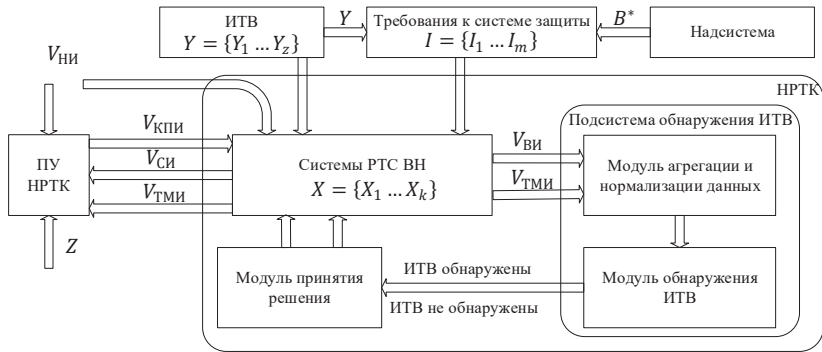


Рис. 1. Функциональная модель процесса обнаружения ИТВ на системы НРТК

В представленной модели (рис. 1) выделены:

- множество ИТВ злоумышленника $Y = \{Y_1, \dots, Y_z\}$
- потребности надсистемы в информации от НРТК $\{B^*\}$;
- множество требований к системе защиты информации $I = \{I_1, \dots, I_m\}$;
- цель управления НРТК $\{B\}$ в интересах удовлетворения потребностей надсистемы;
- множество систем НРТК $X = \{X_1, \dots, X_k\}$;
- информация, циркулирующая в НРТК $\{V_{кпи}, V_{си}, V_{тми}, V_{ни}, V_{ви}\}$ по результатам анализа (B, Y) :

$V_{кпи} = \varphi_1(B, Y)$, где φ_1 – алгоритм формирования командно-программной информации и управления НРТК;

$V_{си} = \varphi_2(B, Y)$, где φ_2 – алгоритм формирования специальной (целевой) информации на ПУ при выполнении НРТК;

$V_{тми} = \varphi_3(B, Y)$, где φ_3 – алгоритм формирования телеметрической информации о состоянии систем НРТК;

$V_{ви} = \varphi_4(V_{тми}, B, Z)$, где φ_4 – алгоритм формирования внутренней информации;

$J = \varphi_5(V_{кпи}, V_{си}, V_{тми}, V_{ни}, Y)$, где φ_5 – алгоритм обнаружения ИТВ.

В представленной модели (рис. 1) подсистема обнаружения ИТВ представлена модулем агрегации и нормализации данных и модулем обнаружением ИТВ. Отличительными признаками модели является дополнительный контур прохождения внутренней информации о состоянии контролируемых систем (элементов) НРТК, в том числе системы защиты информации.

Примерами характеристик (параметров), которые подлежат контролю для обнаружения аномалий, возникающих вследствие ИТВ, в ходе функционирования НРТК могут служить следующие механизмы:

- встроенные таймеры, контроль динамического тока и температуры в большом количестве точек;
- контроль частоты питающего напряжения и тактовых генераторов;
- контроль загруженности узлов микропроцессора и системного контроллера: встроенные счетчики для различных типов событий; контроль времени выполнения кода; контроль точек входа и выхода для системных вызовов; аппаратная поддержка теневого стека, содержащего адреса возвратов и недоступный для пользовательских программ, если адреса вызовов в обычном и теневом стеке различаются, то это свидетельствует об атаке типа «переполнение буфера»;
- механизмы доверенной загрузки, защиты от извлечения кода и данных из микроконтроллеров/специпроцессоров, поддержка рандомизации адресного пространства и аппаратный датчик случайных чисел;
- контроль микропроцессоров (закладки на проводниках, разъемах, переходных отверстиях; защита физического уровня каналов с помощью создания в интерфейсном контроллере контрольного символа с введением специального шифра, для надежного отделения «своего» от «чужого» и предотвращения атаки через коммуникационный канал и т. д.
- диагностика операционной системы (ошибки питания, защита памяти, стека и т. д.);
- контроль системы защиты информации (контроль за выполнением требований политик информационной безопасности и политик управления доступом и т. д.).

На основании концептуального подхода и функционального моделирования разработана методика обнаружения ИТВ на системах НРТК, которая включает последовательность шагов.

Шаг 1. Настройка систем и модулей НРТК. Определение исходных данных, ограничений и допущений.

Шаг 2. Формирование системы сенсоров (датчиков) и базы данных нормированных параметров функционирования подсистем НРТК. Формирование пороговых значений на контролируемые параметры. Построение модели штатного функционирования НРТК (для каждого контролируемого элемента по вектору признаку создание штатного профиля).

Шаг 3. Измерение сигналов, поступающих с сенсоров (датчиков). Оцифровка значений сигналов. Агрегация и нормализация данных.

Шаг 4. Выбор и построение иммунного идентификатора ИТВ.

Шаг 5. Обучение и тестирование иммунного идентификатора.

Шаг 6. Идентификация ИТВ в ходе выполнения функциональных задач НРТК.

В качестве базовой технологии для обнаружения ИТВ могут выступать искусственные иммунные системы (ИИС). Так, исходя из анализа работ в области построения адаптивных систем защиты информации, был сделан вывод о перспективности применения алгоритмов ИИС [Скатков 2023].

Из преимуществ ИИС можно выделить:

1. Динамическое дообучение – в этом случае ИИС обладает механизмом, позволяющим в режиме работы корректировать базу знаний, исходя из новых угроз (иначе происходит у иных механизмов адаптивной защиты информации, где потребуется переобучение всего механизма).

2. Гибкая масштабируемость – за счет наличия механизма динамического дообучения система способна «на лету» генерировать новые знания о новых инцидентах и автоматически внедрять в свою работу.

Заключение

Представленная в работе формализованная постановка задачи обнаружения ИТВ злоумышленника на НРТК направлена на обеспечение информационной безопасности и устойчивости функциональной НРТК.

На основании построенной функциональной модели процесса обнаружения ИТВ разработана методика обнаружения ИТВ, отличительной особенностью которой является построение иммунного идентификатора ИТВ для выявления отклонения параметров систем НРТК от нормированных (допустимых).

Практическая реализация предлагаемых решений заключается в обеспечении контроля функционирования систем (элементов) НРТК в периоды отсутствия или минимальной нагрузки на вычислительные ресурсы подсистемы обработки и защиты информационных потоков НРТК.

Результаты работы могут быть использованы для задач обеспечения информационной безопасности и устойчивости функционирования робототехнических комплексов любого вида, которые

подвержены ИТВ. Дальнейшее развитие предложенных решений направлено на детализацию и декомпозицию методики до отдельных алгоритмов обнаружения и распознавания ИТВ в режиме времени близком к реальному.

Литература

- Иванов 2016 – *Иванов С.С., Дульнев П.А., Воронович А.В.* Задачи, решаемые перспективными робототехническими комплексами военного назначения сухопутных войск и требования к ним // Труды военно-научной конференции «Роботизация Вооруженных Сил Российской Федерации». М., 2016. С. 28–32.
- Малюк 2004 – *Малюк А.А.* Информационная безопасность: концептуальные и методологические основы защиты информации. Учеб. пособие для вузов. М.: Горячая линия – Телеком, 2004. 280 с.
- Кузнецов 2018 – *Кузнецов Ю.В., Винокуров А.В., Бардаев Э.А.* Теоретические основы обеспечения информационной безопасности робототехнических комплексов // Военная мысль. 2018. № 12. С. 71–78.
- Лисицын 2020 – *Лисицын В.В., Бухонский М.И., Калашников А.В., Чакалов И.А.* Актуальные угрозы безопасности информации, циркулирующей в наземном робототехническом комплексе военного назначения // Информационная безопасность – актуальная проблема современности. Совершенствование образовательных технологий подготовки специалистов в области информационной безопасности: матер. XXI Всерос. межведом. науч.-техн. конф. – 2020 / Отв. ред. А.В. Крупенин. Краснодар: КВВУ, 2020. С. 342–353.
- Скатков 2023 – *Скатков А.В., Скатков А.В., Брюховецкий А.А., Доронина Ю.В., Моисеев Д.В.* Методы и технологии обнаружения уязвимостей интерфейсов беспилотных транспортных средств на основе иммунных моделей. Симферополь: ООО «Издательство» Типография «Ариал», 2023. 252 с.

References

- Ivanov, S.S. Dulnev, P.A. and Voronovich, A.V. (2016), “Tasks Solved by Advanced Military-Purpose Robotic Systems of the Ground Forces and Requirements for Them”, *Trudy voenno-nauchnoi konferentsii «Robotizatsiya Vooruzhennykh Sil Rossiiskoi Federatsii»* [Proceedings of the Military Scientific Conference “Robotization of the Armed Forces of the Russian Federation”], Moscow, Russia, pp. 28–32.
- Malyuk, A.A. (2004), *Informatsionnaya bezopasnost’: kontseptual’nye i metodologicheskie osnovy zashchity informatsii. Ucheb. posobie dlya vuzov* [Information Security: Conceptual and Methodological Foundations of Information Protection. Textbook for universities], Goryachaya liniya – Telekom, Moscow, Russia, 280 p.

- Kuznetsov, Yu.V., Vinokurov, A.V. and Bardaev, E.A. (2018), “Theoretical Foundations of Ensuring Information Security of Robotic Systems”, *Military Thought*, no. 12, pp. 71–78.
- Lisitsyn, V.V. Bukhonskii, M.I. Kalashnikov, A.V. and Chakalov, I.A. (2020), “Actual threats to the security of information circulating in a ground-based robotic complex for military purposes”, in Krupenin, A.V. (ed.) *Informatsionnaya bezopasnost' – aktual'naya problema sovremennosti. Sovershenstvovanie obrazovatel'nykh tekhnologii podgotovki spetsialistov v oblasti informatsionnoi bezopasnosti: mater. XXI Vseros. mezhdvost. nauch.-tekhn. konf. – 2020* [Information security is an urgent problem of our time. Improvement of educational technologies for training specialists in the field of information security. Proceedings of the 21st All Russian Scientific and technical conference], KVVU, Krasnodar, Russia, pp. 342–353.
- Skatkov, A.V. Bryukhovetsky, A.A., Doronina, Yu.V. and Moiseev, D.V. (2023), *Metody i tekhnologii obnaruzheniya uyazvimostei interfeisov bespilotnykh transportnykh sredstv na osnove immunnykh modelei* [Methods and Technologies for Detecting Vulnerabilities in Unmanned Vehicle Interfaces Based on Immune Models], “Izdatel'stvo” tipografiya “Arial”, LLC, Simferopol, Russia, 252 p.

Информация об авторе

Александр В. Винокуров, доктор технических наук, доцент, Российский государственный гуманитарный университет, Москва, Россия; 125047, Россия, Москва, Миусская пл., д. 6, стр. 6; VAV73@rambler.ru

Information about the author

Aleksandr V. Vinokurov, Dr. of Sci. (Computer Science), associate professor, Russian State University for the Humanities, Moscow, Russia; 6-6, Miusskaya Sq., Moscow, 125047, Russia; VAV73@rambler.ru

Сравнительный анализ методов машинного обучения в промышленном интернете вещей на нефтеперерабатывающем производстве

Дарья В. Дорогань

*Московский технический университет
связи и информатики (МТУСИ), Москва, Россия,
darya.dorogan.05@bk.ru*

Валерия С. Сикидина

*Московский технический университет
связи и информатики (МТУСИ), Москва, Россия,
sikidina@mail.ru*

Джахед Рахмани

*Московский технический университет
связи и информатики (МТУСИ), Москва, Россия,
jahed@mail.ru*

Аннотация. Развитие промышленного интернета вещей (IIoT) и методов машинного обучения (ML) создало новые возможности для цифровой трансформации нефтеперерабатывающей отрасли. Объединение новых технологий и информации, получаемой ежедневно с производственного оборудования, позволяет повысить эффективность работы и осуществить переход к проактивному подходу к управлению.

Целью данной работы является рассмотрение возможности применения машинного обучения в рамках IIoT на нефтеперерабатывающих производствах, а также обсуждение ключевых перспектив развития использования данных технологий в промышленности.

В работе рассматриваются ключевые направления применения алгоритмов ML на основе данных IIoT, таких как обнаружение аномалий технологических параметров, предиктивное обслуживание оборудования, оптимизацию логистических процессов и прогнозирование коррозионных изменений. Для этих задач были проанализированы и сопоставлены методы Isolation Forest, LSTM, SVM и XGBoost с точки зрения их применимости в условиях высокой изменчивости и многомерности промышленных данных.

Особое внимание уделено моделированию сценариев перегрева технологического оборудования с помощью рекуррентных нейронных

© Дорогань Д.В., Сикидина В.С., Рахмани Д., 2026

сетей LSTM. Полученные результаты подтвердили способность модели воспроизводить нелинейные зависимости во временных рядах и предсказывать критические отклонения с высокой степенью точности. В данном исследовании показано на практике, что использование нейронных сетей позволяет повысить стабильность производственных процессов.

Проведенный сравнительный анализ демонстрирует, что интеграция машинного обучения с промышленными цифровыми системами создает фундамент для построения адаптивных и самообучающихся производственных сред. Такие решения формируют технологическую основу для устойчивого развития нефтеперерабатывающих предприятий и их перехода к концепции Индустрии 4.0, где приоритет смещается от реагирования на проблемы – к их предотвращению.

Ключевые слова: промышленный интернет вещей (IIoT), машинное обучение (ML), нефтеперерабатывающая промышленность, предиктивное обслуживание, обнаружение аномалий, прогнозирование коррозии, Индустрия 4.0, Isolation Forest, LSTM, SVM и XGBoost

Для цитирования: Дорогань Д.В., Сикидина В.С., Рахмани Д. Сравнительный анализ методов машинного обучения в промышленном интернете вещей на нефтеперерабатывающем производстве // Вестник РГГУ. Серия «Информатика. Информационная безопасность. Математика». 2026. № 1. С. 19–34. DOI: 10.28995/2686-679X-2026-1-19-34

Comparative analysis of machine learning methods in the industrial Internet of Things at oil refining production

Darya V. Dorogan

*Moscow technical university of communications
and informatics (MTUCI), Moscow, Russia, darya.dorogan.05@bk.ru*

Valeria S. Sikidina

*Moscow technical university of communications
and informatics (MTUCI), Moscow, Russia, sikidinav@mail.ru*

Dzhakhed Rakhmani

*Moscow technical university of communications
and informatics (MTUCI), Moscow, Russia, jahed@mail.ru*

Abstract. The development of the Industrial Internet of Things (IIoT) and machine learning (ML) methods has created new opportunities for the digital transformation of the oil refining industry. Combining new technologies and

information received daily from production equipment makes it possible to increase work efficiency and make the transition to a proactive management approach.

The purpose of this article is to consider the possibility of using machine learning in the IIoT in the oil refining industry, as well as to discuss key prospects for the development of the use of these technologies in industry.

This article discusses key areas of application of ML algorithms based on IIoT data, such as detection of anomalies in technological parameters, predictive maintenance of equipment, optimization of logistical processes, and prediction of corrosion changes. For these tasks, Isolation Forest, LSTM, SVM, and XGBoost methods were analyzed and compared in terms of their applicability in conditions of high variability and multidimensionality of industrial data.

Special attention is paid to modeling scenarios of overheating of technological equipment using recurrent neural networks LSTM. The results obtained confirmed the model's ability to reproduce nonlinear dependencies in time series and predict critical deviations with a high degree of accuracy. This study shows in practice that the use of neural networks can improve the stability of production processes.

The comparative analysis demonstrates that the integration of machine learning with industrial digital systems creates the foundation for building adaptive and self-learning production environments. Such solutions form the technological basis for the sustainable development of oil refineries and their transition to the concept of Industry 4.0, where the priority is shifting from responding to problems to preventing them.

Keywords: Industrial Internet of Things (IIoT), Machine Learning (ML), oil refining industry, predictive maintenance, anomaly detection, corrosion prediction, Industry 4.0, Isolation Forest, LSTM, SVM, XGBoost

For citation: Dorogan, D.V., Sikidina, V.S. and Rakhmani, D. (2026), "Comparative analysis of machine learning methods in the industrial Internet of Things at oil refining production", *RSUH/RGGU Bulletin. "Information Science. Information Security. Mathematics" Series*, no. 1, pp. 19–34, DOI: 10.28995/2686-679X-2026-1-19-34

Введение

Интернет вещей (IoT) – это информационная сеть физических объектов (датчиков, машин, автомобилей, зданий и других предметов), которая объединяет все эти объекты и позволяет им взаимодействовать друг с другом для достижения общих целей [Андреев, Третьяков 2019]. Однако наиболее значимым направ-

лением развития IoT является его промышленная версия – промышленный интернет вещей (IIoT), который ориентирован на применение в промышленности, включая нефтеперерабатывающие, химические и другие производства [Xu, Xu, Li 2018]. IIoT является более сложной сетью, так как от результатов ее работы зависит работоспособность целого предприятия, а кратковременное отключение несет за собой зачастую катастрофические последствия, в отличие от сети обычного IoT, используемого в повседневной жизни [Рахмани, Рогов 2022]. Помимо этого, IIoT является частью Индустрии 4.0 – Четвертой промышленной революции. Для того, чтобы предприятие оставалось конкурентоспособным в новой реальности, необходимо внедрять новые технологии и следовать актуальным трендам в сфере информационных технологий [Рахмани 2022].

Машинное обучение (ML) – это подраздел искусственного интеллекта, который позволяет компьютерам обучаться на основе данных и делать прогнозы или принимать решения без явного программирования. В контексте IoT и IIoT машинное обучение играет ключевую роль в обработке и анализе больших объемов данных, которые генерируются устройствами и датчиками [Goodfellow, Bengio, Courville 2016].

Нами был проведен анализ предметной области, а именно тенденций текущего развития промышленного интернета вещей, и были предложены возможные направления применения машинного обучения на производстве. Вместе с этим были проведены обзор и сравнение различных моделей ML в контексте их применения в IIoT.

Для рассмотрения мы выбрали сферу нефтеперерабатывающих производств, так как она актуальна и имеет множество возможностей для применения промышленного интернета вещей (IIoT) в сочетании с машинным обучением (ML). Современные нефтеперерабатывающие производства сталкиваются с необходимостью оптимизации процессов, повышения эффективности и снижения затрат. IIoT позволяет собирать и анализировать большие объемы данных с оборудования и датчиков, а машинное обучение предоставляет возможности для прогнозирования, оптимизации и автоматизации процессов.

Целью данной работы является рассмотрение возможности применения машинного обучения в рамках IIoT на нефтеперерабатывающих производствах, а также обсуждение ключевых перспектив развития использования данных технологий в промышленности.

Быстрое развитие промышленности и информационно-коммуникационных технологий обусловило усложнение технических систем и оборудования. Нередко это приводит к нарушению нормального функционирования небольшого объекта инфраструктуры и, таким образом, к нарушению работы всей системы в целом. Отказ машинных агрегатов может повлечь за собой возникновение аварийных ситуаций, сопровождающихся значительным ущербом. Классические подходы к организации технического обслуживания и ремонта оборудования в таких условиях в значительной мере теряют свою эффективность и не удовлетворяют требованиям современной промышленности [Квонг, Щербаков 2020]. Предприятие, чтобы оставаться конкурентоспособным, востребованным и безопасным, должно следить за новейшими тенденциями технического рынка и своевременно вводить в эксплуатацию новые технологии.

Для того, чтобы предотвратить возникновение аварийных ситуаций, многие производства начинают осуществлять внедрение устройств промышленного интернета вещей для более эффективного отслеживания состояния важных процессов. Первый шаг – это установка датчиков, которые способны считывать состояние окружающей среды. Они являются главным источником информации, на основе которой осуществляется работа системы в целом. Стоит отметить, что первично данные должны обрабатываться локальным вычислительным блоком датчика и только потом отправляться для децентрализованных вычислений в модуль обработки данных, так как таким образом сокращается общее время обработки [Андреев, Третьяков 2019].

В промышленном интернете вещей можно выделить два вида взаимодействия: машинная связь (machine to machine, M2M) и связь машина-человек (machine to human, M2H) [Андреев, Третьяков 2019]. Именно внедрение устройств, взаимодействующих в соответствии с данными типами связи, мы и будем рассматривать далее.

Углубимся в специфику нефтеперерабатывающего производства и предположим, где могут использоваться «умные» устройства и какие процессы можно с их помощью автоматизировать, в том числе используя модели машинного обучения как инструмент для прогнозирования. Обязательными для установки являются датчики давления, вибрации и температуры, так как с их помощью можно собирать данные о практически всех процессах, которые касаются добычи природных ископаемых и безопасности их транспортировки.

В общем, все алгоритмы машинного обучения можно разделить на две большие категории: обучение без учителя и обучение с учителем¹. Разделение на две категории происходит в соответствии с поведением алгоритма во время обучения.

Алгоритмы обучения без учителя изучают набор данных, содержащий множество характерных признаков, а затем изучают полезные признаки структуры данного набора данных. Некоторые из алгоритмов обучения без учителя также могут разбивать изначальный набор данных на подгруппы с структурой, похожей на изначальный набор данных.

Алгоритмы обучения с учителем работают с набором данных, которые содержат признаки, ассоциированные с определенной меткой. Например, с помощью алгоритма обучения с учителем можно изучить набор данных для дальнейшей классификации похожего набора данных.

Некоторые алгоритмы из данной классификации могут работать с постоянно изменяющимися данными, адаптируясь к ним, что необходимо в контексте работы с данными, поступающими с производства.

Отслеживание аномальных значений

Говоря о транспортировке, мы можем предположить наличие датчиков давления внутри труб, которые отслеживают состояние непрерывно в течение всего процесса передачи. Предельное значение давления рассчитывается по специальным формулам, указанным в руководстве по безопасности «Методические рекомендации по определению допустимого рабочего давления магистральных нефтепроводов и нефтепродуктопроводов», в соответствии с видом нефтепродукта и видами оборудования, которое используется для транспортировки.

Как только датчик зафиксирует аномальное значение давления (т. е. превышающее предельное значение), то умное устройство отправляет сигнал тревоги инженерам, которые и предпринимают действия для решения проблемы. Здесь обеспечивается связь M2H.

¹ *Heaton J.T.* Ian Goodfellow, Yoshua Bengio, and Aaron Courville. Deep learning. New York: The MIT Press, 2016, 800 p. // Genetic Programming and Evolvable Machines. 2017. Vol. 19 (1-2). URL: https://www.researchgate.net/publication/320703571_Ian_Goodfellow_Yoshua_Bengio_and_Aaron_Courville_Deep_learning_The_MIT_Press_2016_800_pp_ISBN_0262035618 (дата обращения: 11.11.2025).

Машинное обучение может помочь в прогнозировании возможных сбоев на основании статистики, собранной за время эксплуатации датчиков на нефтепроводе или нефтепродуктопроводе. Благодаря результатам прогнозирования, устройства промышленного интернета вещей получают возможность немного заранее предупреждать персонал о возможном сбое, что поможет предотвратить аварийные ситуации и обеспечить безопасность на всем пути движения продукта.

Для отслеживания аномальных значений может использоваться алгоритм «изолирующий лес».

Изолирующий лес (Isolation Forest, iForest) – это алгоритм машинного обучения, предназначенный для обнаружения аномалий, относится к категории алгоритмов без учителя. Он основан на идее, что аномалии являются редкими и существенно отличаются от нормальных данных, поэтому их можно «изолировать» за меньшее количество шагов по сравнению с нормальными точками. Данный алгоритм имеет линейную временную сложность:

$$T_{\text{isolationForest}} = O(nt \log n),$$

где n – размер массива данных, t – количество деревьев [Liu, Ting, Zhou 2008].

Изолирующий лес использует ансамбль деревьев (forest), каждое из которых строится случайным образом. В отличие от традиционных деревьев решений, которые разделяют данные для максимизации информативности, деревья в изолирующем лесе разделяют данные случайным образом, выбирая случайный признак и случайное значение для разделения. Аномалии, будучи редкими и отличающимися, изолируются быстрее, то есть требуют меньшего количества разделений, чтобы быть отделенными от остальных данных [Liu, Ting, Zhou 2008].

Для того, чтобы эта модель работала корректно, предварительно ее нужно обучить на исторических данных без аномалий. Готовая модель будет в реальном времени оценивать данные, приходящие на датчики, и выявлять аномалии. При их возникновении система сможет отправить аварийный сигнал.

Предиктивное обслуживание

Благодаря информации с датчиков и машинному обучению можно предугадать, когда оборудование выйдет из строя, что также помогает избежать плохого исхода событий. Такое использование технологий также называется предиктивным обслуживанием. Для

этого могут использоваться различные методы машинного обучения, например LSTM.

LSTM (Long Short-Term Memory) – это тип рекуррентной нейронной сети, разработанный для эффективной работы с последовательностями данных, такими как временные ряды или текстовые данные. Данный алгоритм не требует определенного набора данных: он будет работать как с преобразованным набором, так и с оригинальным. Основная проблема, которую решает LSTM, заключается в способности запоминать долгосрочные зависимости в данных, что особенно важно для задач, где контекст или история играют ключевую роль. В отличие от традиционных рекуррентных нейронных сетей (RNN), которые страдают от проблемы исчезающего градиента и теряют информацию на длинных последовательностях, LSTM использует механизм «ворот» (gates) для управления потоком информации. Эти ворота включают забывающий gate, который решает, какую информацию из прошлого следует забыть, входной gate, определяющий, какую новую информацию добавить в память, и выходной gate, который регулирует, какая информация будет передана на выход. Ячейка памяти (cell state) служит долгосрочным хранилищем информации, обновляемым на каждом шаге. Благодаря этой архитектуре, LSTM способна эффективно обрабатывать длинные последовательности, сохраняя важные данные и отбрасывая ненужные [Zhao, Yan, Chen, Mao, Wang, Gao 2019; Zhang, Zhang 2019]. Вычислительная сложность данного алгоритма составляет $T_{LSTM} = O(1)$ на временном шаге [Hochreiter and Schmidhuber 1997].

Данный алгоритм может работать длительное время, запоминая информацию и анализируя ее. С его помощью система может предсказать возможный сбой оборудования, чем уменьшит количество аварий.

Исследования показывают, что использование распределенных сетей датчиков (газоанализаторов, акустических и ультразвуковых сенсоров) в сочетании с алгоритмами аномалийного обнаружения (Isolation Forest, LSTM-сети) снижает частоту ложных срабатываний, таких как ложные аварийные сигналы и ошибочные прогнозирование отказов, на 30–40% по сравнению с традиционными пороговыми системами [Zhang 2023].

Логистика

Помимо транспортировки, промышленный интернет вещей и машинное обучение помогают в логистике. Например, определенные сенсоры могут отслеживать уровень заполненности резервуара,

из которого берется сырье для переработки. Если оно расходуется неравномерно, машинное обучение, используя данные с этих сенсоров, поможет спрогнозировать, когда понадобится дополнительная порция сырья, а устройства промышленного интернета вещей получат возможность отправлять сигналы автоматизированной системе для пополнения резервуара. Здесь обеспечивается связь М2М. Для подобных задач обычно применяется метод опорных векторов.

Метод опорных векторов (SVM) – это алгоритм машинного обучения, который помогает разделять данные на классы. Относится к категории алгоритмов с учителем. Он ищет лучшую границу (гиперплоскость) между классами, чтобы она была как можно дальше от данных каждого класса. Если данные нельзя разделить прямой линией, SVM использует специальные функции (ядра), чтобы «перевести» данные в пространство, где их уже можно разделить [Chang, Lin 2011]. Временная сложность данного алгоритма оценивается в $T_{SVM} = O(n^3)$ [Abdiansah, Wardoyo 2015].

SVM может классифицировать уровень заполненности резервуара как «нормальный» или «критический» на основе исторических данных о расходе сырья, что позволяет автоматизировать процесс пополнения и минимизировать простои.

Прогнозирование коррозии

Важным направлением является прогнозирование коррозии оборудования. Применение электрохимических датчиков и ультразвуковых толщиномеров, передающих данные в режиме реального времени, позволяет алгоритмам градиентного бустинга прогнозировать остаточный ресурс трубопроводов с точностью до 90%² [Kermani 2022]. Например, на НПЗ компании BP внедрение системы “Corrosion Predict” на основе ML сократило затраты на внеплановые ремонты на 40%³. Примером алгоритма градиентного

² Waziri A.M., Guma T.N., Akindapo J.O., Orueri D.U. Machine learning-based prediction of external corrosion rates ni buried unprotected gas pipelines // Nigerian Journal of Engineering Science and Technology Research. 2025. Vol. 11. No. 2. P. 11–23. URL: https://www.researchgate.net/publication/393981106_MACHINE_LEARNING-BASED_PREDICTION_OF_EXTERNAL_CORROSION_RATES_IN_BURIED_UNPROTECTED_GAS_PIPELINES (дата обращения: 11.12.2025).

³ BP Sustainability Report. Digital Transformation in Refinery Asset Integrity, 2023. URL: <https://companiesmarketcap.com/sustainability-reports/61.sar.en.2023.pdf> (дата обращения: 11.12.2025).

бустинга, который может быть использован для этих целей, является XGBoost.

XGBoost (eXtreme Gradient Boosting) – это мощный алгоритм машинного обучения, основанный на градиентном бустинге, который сочетает в себе последовательное построение ансамбля слабых предсказателей, обычно деревьев решений, с оптимизацией градиентного спуска для минимизации функции потерь. Он относится к категории алгоритмов с учителем. В отличие от традиционного градиентного бустинга, XGBoost включает регуляризацию для борьбы с переобучением. Алгоритм поддерживает параллельные и распределенные вычисления, что делает его масштабируемым для больших объемов данных. Максимальная временная сложность алгоритма составляет $T_{XGBoost} = O(Kd \|x\|_0 \log n)$, где K – общее количество деревьев, d – максимальный размер дерева, а $\|x\|_0$ – количество отсутствующих значений в обучающих данных [Chen, Guestrin 2016].

Сравнение методов машинного обучения

В табл. 1 представлено сравнение описанных выше методов машинного обучения при использовании их в совокупности с промышленным интернетом вещей.

Практическое применение методов машинного обучения

Для более наглядного представления возможностей использования данных технологий в нефтеперерабатывающей области смоделируем возможный вариант применения алгоритма машинного обучения LSTM для предсказания перегрева оборудования.

Так как большая часть оборудования, используемого на нефтеперерабатывающих производствах, работает непрерывно длительное время, оно подвержено перегреву. Выход из зоны разрешенных температур может привести к авариям. Чтобы избежать этого, необходимо применять алгоритмы предиктивного обслуживания, которые будут предсказывать температуру оборудования в разное время и сигнализировать о возможном чрезмерном нагреве.

Таблица 1

Сравнение методов машинного обучения

Метод	Категория	Временная сложность	Тип данных	Применение	Плюсы	Минусы
Isolation Forest	Алгоритм с учителем	$O(n \log n)$	Табличные, многомерные	Отслеживание аномальных значений	Эффективен на больших данных, хорошо обнаруживает аномалии в многомерных данных	Менее точен на данных с высокой размерностью
LSTM	Алгоритм с учителем/ без учителя	$O(1)$	Последовательные (временные ряды)	Предиктивное обслуживание	Учитывает долгосрочные зависимости, хорош для прогнозирования временных рядов, автоматически извлекает признаки	Требует много данных для обучения, высокие вычислительные затраты, сложен в настройке
SVM	Алгоритм с учителем	$O(n^3)$	Табличные, многомерные	Логистика	Эффективен в высокоразмерных пространствах, устойчив к переобучению (с правильными параметрами)	Медленный на больших данных, чувствителен к выбору гиперпараметров, плохо интерпретируется
XGBoost	Алгоритм с учителем	$O(Kd \ x\ _0 \log n)$	Табличные (разреженные и полные)	Прогнозирование коррозии оборудования	Высокая точность, встроенная регуляризация против переобучения, поддержка пропущенных значений, быстрая работа	Склонен к переобучению при неправильной настройке, менее интерпретируемый, чем деревья решений, требует тонкой настройки гиперпараметров

Для демонстрации работы алгоритма был сгенерирован синтетический набор данных, моделирующий температуру прибора при непрерывной работе. Моделирование основано на физико-математическом подходе, учитывающем ключевые операционные параметры: механическую нагрузку, рабочее давление, износ оборудования, температуру окружающей среды. Температурная динамика вычисляется по детерминировано-стохастической схеме. Модель сочетает предсказуемые физические функции со случайными шумами, что позволяет воспроизвести сложное и нелинейное поведение реального оборудования.

Сформированный набор данных содержит 5000 многомерных временных последовательностей с длиной отсчетов равной пятидесяти, которые описывают как состояния штатной работы оборудования, так и аварийные ситуации с перегревом.

Для обучения нейронной сети данные были нормализованы в диапазон $[0, 1]$.

Все данные были разделены на обучающую и тестовую выборки. Тестовой выборкой стали 20% от всей выборки, то есть 1000 временных последовательностей, включающие состояния перегрева.

Архитектура нейронной сети состояла из трех последовательных LSTM слоев с уменьшающейся размерностью 64–32–16 нейронов, каждый из слоев был дополнен механизмами регуляризации. Функцией потерь была выбрана среднеквадратичная ошибка MSE.

На рис. 1 представлены графики для трех случайных тестовых случаев аварийной ситуации, на рис. 2 изображены графики для трех случайных тестовых случаев штатной работы. Графики демонстрируют насколько точно модель предсказывает температуру при различных обстоятельствах.

Анализ результатов визуализации подтверждает возможность модели достаточно точно предсказывать нелинейные зависимости для разных эксплуатационных режимах.

Из рисунка видно, что модель предсказывает данные с достаточной степенью точности. Для тестовых данных средняя абсолютная ошибка MAE примерно равна трем градусам цельсия. Эти результаты свидетельствуют о том, что модель адекватно предсказывает данные.

Данная модель носит демонстрационный характер, что объясняет некоторые неточности в прогнозировании. В случае реального использования данного алгоритма на производстве модель станет более сложной и многоуровневой, а данные будут реальными. В таком случае предсказания модели будут максимально точными и полезными.




Рис. 1. Сравнение прогноза и реальных данных для аварийных ситуаций




Рис. 2. Сравнение прогноза и реальных данных для штатной работы

Заключение

В ходе работы были рассмотрены методы машинного обучения и возможности их интеграции с промышленным интернетом вещей для применения на нефтеперерабатывающем производстве. Проведенный анализ и моделирование показали, что алгоритм Isolation Forest подходит для эффективного выявления аномальных значений параметров оборудования, что способствует повышению безопасности и снижению риска аварийных ситуаций. Применение нейронных сетей LSTM подходит для задач предиктивного обслуживания, позволяя прогнозировать отказы оборудования и планировать технические работы с минимальными потерями производительности. Метод SVM показал потенциал в задачах оптимизации логистических процессов. Алгоритм XGBoost подходит

для прогнозирования скорости коррозии оборудования, обеспечивая точные предсказания на основе эксплуатационных данных IoT-систем.

Кроме того, было проведено моделирование возможного применения алгоритма LSTM для предсказания перегрева оборудования, что позволяет возможные аварии на производстве. Данное моделирование показало, что модель адекватно предсказывает данные и имеет низкие показатели средней абсолютной ошибки MAE около трех градусов Цельсия, что допустимо для нашей задачи.

Результаты исследования подтверждают, что сочетание технологий промышленного интернета вещей и методов машинного обучения позволяет значительно снизить вероятность аварий и повысить общую надежность системы за счет мониторинга состояния оборудования и прогнозирования его состояния. Это подтверждает, что предложенные в работе решения могут быть практически реализованы на реальном предприятии для решения проблем безопасности производства.

Литература

- Андреев, Третьяков 2019 – *Андреев Ю.С., Третьяков С.Д.* Промышленный интернет вещей. СПб.: ИТМО, 2019. 54 с.
- Квонг, Щербаков 2020 – *Квонг Сай Ван, Щербаков М.В.* Архитектура системы предсказательного технического обслуживания сложных многообъектных систем в концепции Индустрии 4.0 // Программные продукты и системы. 2020. № 2. С. 186–194.
- Рахмани 2022 – *Рахмани Д.* Исследование методов управления рисками в инфокоммуникационной системе энергопроизводящей компании Исламской Республики Иран // Т-Comm: Телекоммуникации и транспорт. 2022. Т. 16. № 8. С. 30–37.
- Рахмани, Рогов 2022 – *Рахмани Д., Рогов И.Д.* Тенденции развития сетевых технологий в 2022 году // Технологии информационного общества: Сборник трудов XVI Международной отраслевой научно-технической конференции, Москва, 2–3 марта 2022 г. М.: ООО «Издательский дом Медиа публишер», 2022. С. 30–31.
- Chang, Lin 2011 – *Chang C.-C., Lin C.-J.* LIBSVM: A Library for Support Vector Machines // ACM Transactions on Intelligent Systems and Technology. 2011. Vol. 2 (3). P. 1–27.
- Chen, Guestrin 2016 – *Chen T., Guestrin C.* Xgboost: A scalable tree boosting system // Proceedings of the 22nd ACM SIGKDD International Conference on knowledge discovery and data mining. New York: ACM, 2016. P. 785–794.

- Liu, Ting, Zhou 2008 – *Liu F.T., Ting K.M., Zhou Z.H.* Isolation Forest // Eighth IEEE International Conference on Data Mining, New York, NY: IEEE, 2008. P. 413–422.
- Xu, Xu, Li 2018 – *Xu L.D., Xu E.L., Li L.* Industry 4.0: state of the art and future trends // International Journal of Production Research. 2018. Vol. 56, issue 8. P. 2941–2962.
- Zhang, Zhang 2019 – *Zhang C., Zhang S.* Predictive maintenance using machine learning: a review // IEEE Access. 2019. Vol. 7. P. 108454–108466.
- Zhang 2023 – *Zhang X.*, et al. OptIForest: Optimal Isolation Forest for Anomaly Detection. URL: <https://arxiv.org/pdf/2306.12703> (дата обращения: 11.12.2025).
- Zhao, Yan, Chen, Mao, Wang, Gao 2019 – *Zhao R., Yan R., Chen Z., Mao K., Wang P., Gao R.X.* Deep learning and its applications to machine health monitoring // Mechanical Systems and Signal Processing. 2019. Vol. 115. P. 213–237.

References

- Andreev, Yu. and Tret'yakov, S. (2019), *Promyshlennyyi internet veshchei* [Industrial Internet of Things], Universitet ITMO, Saint Petersburg, Russia, 54 p.
- Chang, C.-C. and Lin, C.-J. (2011), “LIBSVM: A Library for Support Vector Machines”, *ACM Transactions on Intelligent Systems and Technology*, vol. 2 (3), pp. 1–27.
- Chen, T. and Guestrin, C. (2016), “Xgboost: A scalable tree boosting system”, *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, ACM, New York, USA, pp. 785–794.
- Liu, F.T., Ting, K.M. and Zhou, Z.H. (2008), “Isolation Forest”, *Eighth IEEE International Conference on Data Mining*, IEEE, New York, NY, pp. 413–422.
- Rakhmani, D. (2022), “Research of risk management methods in the infocommunication system of an energy producing company in the Islamic Republic of Iran”, *T-Comm: Telecommunications and Transport*, vol. 16, no. 8, pp. 30–37.
- Rakhmani, D. and Rogov, I.D. (2022), “Trends in the development of network technologies in 2022”, *Information Society Technologies. Proceedings of the 26th International Industrial Scientific and Technical Conference, Moscow*, Media Publisher Publishing House, LLC, Moscow, Russia, pp. 30–31.
- Sai, Van K. and Shcherbakov, M.V. (2020), “The architecture of the predictive maintenance system for complex multi-object systems in the concept of Industry 4.0”, *Programmnye produkty i sistemy*, no. 2, pp. 186–194.
- Xu, L.D., Xu, E.L. and Li, L. (2018), “Industry 4.0: state of the art and future trends”, *International Journal of Production Research*, vol. 56, issue 8, pp. 2941–2962.
- Zhang, C. and Zhang, S. (2019), “Predictive maintenance using machine learning: a review”, *IEEE Access*, vol. 7, pp. 108454–108466.
- Zhang, X., et al. (2023), “OptIForest: Optimal Isolation Forest for Anomaly Detection”, available at: <https://arxiv.org/pdf/2306.12703> (Accessed 11 December 2025).
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P. and Gao, R.X. (2019), “Deep learning and its applications to machine health monitoring”, *Mechanical Systems and Signal Processing*, vol. 115, pp. 213–237.

Информация об авторах

Дарья В. Дорогань, студент, Московский технический университет связи и информатики, Москва, Россия; 111024, Россия, Москва, ул. Авиамоторная, д. 8А; darya.dorogan.05@bk.ru

Валерия С. Сикидина, студент, Московский технический университет связи и информатики, Москва, Россия; 111024, Россия, Москва, ул. Авиамоторная, д. 8А; sikidinav@mail.ru

Джахед Рахмани, Московский технический университет связи и информатики, Москва, Россия; 111024, Россия, Москва, ул. Авиамоторная, д. 8А; jahed@mail.ru

Information about the authors

Darya V. Dorogan, student, Moscow Technical University of Communications and Informatics, Moscow, Russia; bld. 8A, Aviamotornaya Str., Moscow, 111024, Russia; darya.dorogan.05@bk.ru

Valeria S. Sikidina, student, Moscow Technical University of Communications and Informatics, Moscow, Russia; bld. 8A, Aviamotornaya Str., Moscow, 111024, Russia; sikidinav@mail.ru

Dzhakhed Rakhmani, Moscow Technical University of Communications and Informatics, Moscow, Russia; bld. 8A, Aviamotornaya Str., Moscow, 111024, Russia; jahed@mail.ru

Анализ библиотек языка PYTHON для решения задач оптимизации в студенческих прикладных исследованиях

Анна Б. Клименко

*Российский государственный гуманитарный университет,
Москва, Россия, anna_klimenko@mail.ru*

Вадим В. Жепан

*Российский государственный гуманитарный университет,
Москва, Россия*

Аннотация. Технологии и системы искусственного интеллекта активно используются в образовательном процессе: широкий круг прикладных исследовательских проектов студентов направлен на разработку новых методов и алгоритмов машинного обучения, а также систем искусственного интеллекта. Проектный подход актуален в современном образовании, однако не лишен ряда проблем, включая недостаток компетенций и мотивации студентов, что актуализирует вопрос рационализации использования программных средств. В статье проведен анализ библиотек языка PYTHON, реализующих современные методы оптимизации, в контексте выполнения прикладных исследований студентами 3–4 курсов направления 01.03.04 «Прикладная математика» с целью получения оценок целесообразности использования тех или иных библиотек. Выбор библиотек обоснован повсеместной интеграцией методов оптимизации в экосистему искусственного интеллекта, начиная от управления ресурсами, необходимыми для обучения моделей, и заканчивая собственно обучением моделей. Для исследования выделены три базовых показателя эффективности программных библиотек – возможности визуализации, возможности работы с данными, возможности кастомизации алгоритмов. Для каждого базового свойства также были выделены составляющие показатели эффективности, позволяющие формально описать возможности библиотек. Проведенное анкетирование и приведенные примеры наглядно демонстрируют существенные различия библиотек PYTHON в плане удобства их использования, и подтверждает актуальность многокритериальной их оценки.

Ключевые слова: проектная деятельность, прикладные исследовательские проекты, машинное обучение, искусственный интеллект, алгоритмы оптимизации, программные библиотеки, PYTHON

© Клименко А.Б., Жепан В.В., 2026

Для цитирования: Клименко А.Б., Жепан В.В. Анализ библиотек языка PYTHON для решения задач оптимизации в студенческих прикладных исследованиях // Вестник РГГУ. Серия «Информатика. Информационная безопасность. Математика». 2026. № 1. С. 35–54. DOI: 10.28995/2686-679X-2026-1-35-54

Analysis of Python libraries for solving optimization problems in student applied research

Anna B. Klimenko

*Russian State University for the Humanities,
Moscow, Russia, anna_klimenko@mail.ru*

Vadim V. Zhepan

*Russian State University for the Humanities,
Moscow, Russia*

Abstract. Technologies and Artificial Intelligence systems are actively used in the educational process: a wide range of applied research projects by students is aimed at developing new methods and algorithms for machine learning as well as Artificial Intelligence systems. The project-based approach is relevant in modern education but is not without its problems, including lack of student competencies and motivation, which raises the question of rationalizing software tool usage. This article analyzes Python libraries implementing contemporary optimization methods within the context of conducting applied research by third- and fourth-year undergraduate students majoring in Applied Mathematics (01.03.04). The choice of libraries is justified by the widespread integration of optimization techniques into the Artificial Intelligence ecosystem, ranging from managing resources required for model training to actual model training itself. Three basic properties of programming libraries were highlighted for this study – visualization capabilities, data handling possibilities, and algorithm customization options. For each fundamental property, additional efficiency metrics were also identified, allowing formal description of library features. A conducted survey and presented examples clearly demonstrate significant differences among Python libraries regarding ease of use and confirm the relevance of multi-criteria assessment.

Keywords: project activity, applied research projects, machine learning, Artificial Intelligence, optimization algorithms, software libraries, PYTHON.

For citation: Klimenko, A.B. and Zhepan, V.V. (2026), “Analysis of Python libraries for solving optimization problems in student applied research”, *RSUH/RGGU Bulletin. “Information Science. Information Security. Mathematics” Series*, no. 1, pp. 35–54, DOI: 10.28995/2686-679X-2026-1-35-54

Введение

В настоящее время развитие методов и алгоритмов машинного обучения, в том числе технологии искусственного интеллекта (ИИ), является приоритетным направлением развития отечественной науки и техники. Актуальность направления ставит вопросы о внесении значимых изменений в образовательные программы и рабочие программы дисциплин. При этом внедрение технологий ИИ может быть рассмотрено в двух ракурсах: с точки зрения использования технологий ИИ в образовании и с точки зрения разработки технологий ИИ в рамках образовательного процесса.

Проблема использования технологий ИИ достаточно активно исследуется, а данные исследований публикуются. Например, работа¹ предоставляет результаты анкетирования студентов в части способов использования нейросетевых технологий в процессе обучения. В работе² также приводятся результаты анализа частоты и областей применения учащимися технологий ИИ: до 62% респондентов в 2024 г. использовали ИИ для решения учебных задач. Также актуальные вопросы использования технологий искусственного интеллекта поднимаются в работах³ [Самарина 2023].

В целом по данному направлению общий тренд характеризуется быстрым ростом использования технологий ИИ, в частности, нейросетей, при выполнении лабораторных и курсовых работ, рефератов, при выполнении ВКР, а также при выполнении прикладных исследовательских проектов. Следует отметить, что значимое количество респондентов – обучающихся (62,5%) используют

¹ Прохорова М.П., Шкунова А.А., Булганина С.В. Искусственный интеллект и нейросети в образовании глазами студентов // Проблемы современного педагогического образования. 2024. № 85-2. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-i-neyroseti-v-obrazovanii-glazami-studentov> (дата обращения: 04.12.2025).

² Терёхова Е.С., Пучкова Н.Н., Новикова Л.В. Анализ востребованности использования нейросетей для решения учебных задач // Концепт. 2024. № 8. URL: <https://cyberleninka.ru/article/n/analiz-vostrebovannosti-ispolzovaniya-neyrosetey-dlya-resheniya-uchebnyh-zadach> (дата обращения: 04.12.2025).

³ Shaw C., Yuan L., Brennan D. et al. GenAI in Higher Education: Fall 2023. Update Time for Class Study // Tyton Partners. 2023. URL: <https://tytonpartners.com/app/uploads/2023/10/GenAI-IN-HIGHER-EDUCATION%20FALL-2023-UPDATE-TIME-FOR-CLASS-STUDY.pdf> (дата обращения: 02.12.2025).

результат генерации больших языковых моделей в качестве источника идей для собственных работ [Самарина 2023].

Другой ракурс, в котором может быть рассмотрено использование технологий ИИ в обучении, – это разработка собственных проектов, реализующих технологии и системы ИИ, а также методы машинного обучения в рамках профильных образовательных программ.

В соответствии со статистикой, представленной в работе [Рудник 2025], к настоящему времени разработку в области ИИ ведут в основном научные организации и вузы, а также коммерческие организации сектора информации и связи. Масштабы подготовки высококвалифицированных кадров в области ИИ непрерывно растут. Выпуск по образовательным программам по профилю ИИ в 2023 г. составил 3,8 тыс. чел., по программам иных профилей, содержащим модуль по ИИ, – 64,6 тыс. чел. [Рудник 2025]. Состав технологий ИИ, изучаемых в рамках данного модуля, определяется направлением подготовки (специальностью) образовательной программы. Наиболее широкий спектр технологий ИИ осваивают будущие разработчики программного обеспечения.

Следует отметить направление исследований, посвященных интеграции технологий ИИ и технологий разработки программного обеспечения – как, например, [Nieminen 2025] посвящена исследованию интеграции инструментов ИИ и платформ с низким уровнем кодирования (LCNC) в образовательный процесс начального курса программирования, ориентированного на студентов инженерных и бизнес-программ. Авторы заключают, что интегрированный подход LCNC и ИИ успешно мотивирует студентов, ускоряет приобретение технических навыков и улучшает умение решать проблемы, одновременно выделяя ключевые области для дальнейшего совершенствования в педагогическом подходе и выборе ресурсов. Исследование подчеркивает потенциал этого метода в качестве дополнительного инструмента для традиционных курсов программирования, особенно для студентов с разнообразным техническим бэкграундом.

Актуальность данного исследования определяется тем фактом, что при наличии обширного числа публикаций, посвященных использованию инструментов ИИ студентами для поддержки процесса обучения, не выявлены работы, в которых проводилось бы исследование полезности и эффективности инструментов для разработки технологий, систем и компонентов экосистем ИИ в рамках студенческих прикладных исследовательских проектов.

Следует отметить, что разработка практически любой системы ИИ тесно интегрирована с использованием различных методов

оптимизации, что связано с попытками улучшения моделей машинного обучения – оптимизации гиперпараметров, генерации признаков, оптимизации структуры нейронных сетей. Кроме того, в соответствии с ГОСТ Р 71476-2024 «Искусственный интеллект. Концепции и терминология искусственного интеллекта» экосистема ИИ включает обширное научно-техническое направление ресурсного обеспечения систем ИИ: привлечение необходимых ресурсов, управление ресурсами, что включает управление кластерами и масштабированием ресурсов. Современные тренды решения задач, связанных с управлением ресурсами также основаны на применении методов оптимизации.

В рамках данной статьи внимание акцентируется на изучении и использовании современных методов оптимизации в контексте построения экосистем ИИ. Целью данного исследования является анализ библиотек языка PYTHON, реализующих методы оптимизации, в ракурсе их применения в студенческих прикладных проектах. Задачи, решаемые в исследовании:

- аналитический обзор состояния предметной области – реализации прикладных исследовательских проектов студентами вузов;
- исследование библиотек языка PYTHON, реализующих методы оптимизации;
- выделение показателей эффективности библиотек и проведение тестирования учащихся;
- сравнение примеров реализаций процедур в рамках использования библиотек.

Прикладные исследовательские проекты и программные средства их реализации

Термин «проект» был позаимствован из классического латинского языка, в котором оно изначально означало «выброшенный вперед», «выступающий», «бросающийся в глаза». По определению американского педагога, основоположника метода проектов, Уильяма Херда Килпатрика, проект – это всякое действие, совершаемое от всего сердца и с определенной целью [Pescore 2015].

Проектная деятельность, определяемая как ведущий вид деятельности в подготовке современного инженера, в соответствии с идеологией Всемирной инициативы CDIO, позволяет подготовить инженера, способного к осуществлению профессиональной деятельности в контексте жизненного цикла реальных

систем, процессов и продуктов: *Conceive – Design – Implement – Operate*⁴.

Процесс интеграции студентов в проектную деятельность осуществляется последовательно, исходя из уровня подготовки обучающихся и особенностей этапов инженерного проектирования. Первокурсники демонстрируют проектировочно-внедренческие компетенции в ограниченной степени вследствие недостаточной сформированности теоретической базы и отсутствия специализированных знаний. Проектная активность на начальной стадии выступает как подготовительный этап, целью которого является введение студентов в образовательный контекст проектной среды, освоение основных понятий и принципов проектного подхода, формирование первичных навыков коллективной работы и способность синтезировать междисциплинарные знания при решении конкретных проектных задач. В условиях реализации полного цикла проектирования в концепции CDIO студент способен демонстрировать указанные компоненты компетенций фрагментарно или частично.

Однако, несмотря на некоторую проработанность тематики и общую заинтересованность вузов в ведении студенческой проектной деятельности, нельзя не отметить ряд проблем, возникающих как со стороны студентов, так и преподавателей. Прежде всего упоминается:

- мотивационный, компетентностный дефицит студентов, отсутствие навыков самоорганизации и рефлексии у студентов;
- мотивационный и компетентностный дефицит преподавателей^{5, 6, 7} [Дубровская 2020].

⁴ *Арнаутов А.Д., Рябов О.Н.* Потенциал проектной деятельности студентов в развитии их компетентности // *Современные наукоемкие технологии.* 2017. № 7. С. 87–91. URL: <https://top-technologies.ru/ru/article/view?id=36735> (дата обращения: 30.11.2025).

⁵ *Шкунова А.А., Плешанов К.А.* Организация проектной деятельности студентов в вузе: результаты научного исследования и перспективы развития // *Вестник Мининского университета.* 2017. № 4 (21). С. 4. URL: <https://doi.org/10.26795/2307-1281-2017-4-4> (дата обращения: 04.12.2025).

⁶ *Хамидуллин В.С.* Модернизация модели проектно ориентированного обучения в вузе // *Высшее образование в России.* 2020. Т. 29, № 1. С. 135–149. URL: <https://doi.org/10.31992/0869-3617-2020-29-1-135-149> (дата обращения: 04.12.2025).

⁷ *Липатова С.Д., Хохолева Е.А.* Технология формирования навыков командной работы в условиях проектного обучения студентов вуза // *Вестник Самарского государственного технического университета.*

Компетентностный дефицит студентов может быть значимым препятствием к реализации прикладных исследовательских проектов, поскольку зачастую ведет и к мотивационному дефициту. Отсюда возникает востребованность анализа программных средств с точки зрения удобства их использования, необходимости обладания специальными знаниями и т. д.

Примеры использования методов и алгоритмов машинного обучения, формирование технологий, систем, экосистем искусственного интеллекта в некоторой мере представлены в открытых источниках. Например, на сайте «Студенческие проекты» (<https://ods.ai/tracks/sibfest3-student-projects>) можно увидеть следующие темы: «Влияние выбора модели на автоматическое извлечение терминов», «Извлечение аспектов из текстов научных статей», «Извлечение семантических отношений из текстов научных статей». На портале Высшей школы экономики (<https://studscience.hse.ru/projects2024>) также представлены примерные темы студенческих прикладных исследовательских проектов «Разработка алгоритма для поиска скоплений галактик в инфракрасном обзоре WISE с помощью глубокого обучения», «Тонкая настройка (fine-tuning) открытых больших языковых моделей (LLM) для юридических задач». В рамках первого проекта разрабатывается новый алгоритм на основе нейронных сетей для поиска скоплений галактик в инфракрасном диапазоне при помощи данных обзора WISE. Скопления галактик, являющиеся крупнейшими гравитационно-связанными структурами во Вселенной, особенно интересны в контексте исследования космологических параметров и эволюции Вселенной. Предлагаемое исследование находится на стыке астрофизики и компьютерных наук. Второй проект ориентирован на совершенствование LLM с целью их применения в предметной области юриспруденции. В Институте информационных наук и технологий безопасности Российского государственного гуманитарного университета также был выполнен ряд прикладных исследовательских проектов, например: «Использование эволюционных алгоритмов при решении задач распределения вычислительных ресурсов», «Интеграция эволюционных принципов Дарвина и Ламарка для распределения вычислительных ресурсов», «Интеграция эволюционных принципов Дарвина и Ламарка при решении задачи планирования маршрутов для группы роботов» (что отра-

Серия «Психолого-педагогические науки». 2021. Т. 18, № 1. С. 57–70.
URL: <https://cyberleninka.ru/article/n/tehnologiya-formirovaniya-navykov-komandnoy-raboty-v-usloviyah-proektnogo-obucheniya-studentov-vuza?ysclid=mlgby geci5742975774> (дата обращения: 04.12.2025).

жено в ряде совместных публикаций [Клименко, Ельмекеев 2025; Klímenko 2025]). Также были реализованы проекты «Разработка чат-бота для интернет-магазина “Vefree” с функцией персонализированных рекомендаций на основе предпочтений пользователя», «Анализ новостей с помощью ИИ», «Методы машинного обучения с подкреплением в научных исследованиях».

К настоящему времени в языке PYTHON используются следующие библиотеки, реализующие методы оптимизации.

1. SciPy – одна из старейших и самых популярных библиотек Python для научно-технических расчетов. Содержит широкий спектр классических методов оптимизации, таких как градиентный спуск, Ньютоновские методы, симплекс-метод и другие. Используется для классической оптимизации, расчета минимумов/максимумов функций, поиска корней уравнений.

2. CVXPY – позволяет удобно определять и решать задачи выпуклой оптимизации. Ее синтаксис близок к формальному математическому представлению задачи, что облегчает постановку и решение оптимизационных задач. Удобна для быстрых прототипов и экспериментов с простыми и сложными моделями. Используется для решения задач линейного программирования, квадратичного программирования, оптимизации с ограниченными условиями.

3. PuLP – библиотека для решения задач линейного программирования (Linear Programming, LP) и смешанного целочисленного программирования (Mixed Integer Linear Programming, MIP). Отличается легкостью в использовании и возможностью подключения сторонних решателей.

Может быть интегрирована с другими инструментами, такими как Excel Solver, CPLEX и Gurobi, при этом ограничена исключительно линейными задачами и может быть использована для решения транспортных задач, задач размещения ресурсов, финансовых задач.

4. DEAP (Distributed Evolutionary Algorithms in Python) – библиотека, реализующая алгоритмы эволюционной оптимизации, включающая большинство известных эволюционных алгоритмов, таких как генетические алгоритмы, рои частиц, алгоритм муравьиной колонии и др.

5. SimAnn (Simulated Annealing) – содержит реализацию популярного алгоритма оптимизации, известного как «Имитация отжига». Представляет собой технику стохастического поиска, имитирующую процесс кристаллизации металлов при охлаждении.

6. AutoML Tools (TPOT, H2O.ai, Optuna) – предназначены для автоматизации выбора гиперпараметров и поиска оптимальной

архитектуры моделей машинного обучения. Полностью автоматизируют трудоемкий процесс ручной настройки гиперпараметров.

7. Bayesian Optimization Libraries (GPyOpt, hyperopt) – байесовская оптимизация основана на предположении о вероятности успешного исхода в каждом новом испытании, используя предыдущую историю попыток. Используется для оптимизации гиперпараметров.

8. Metaheuristic Libraries (Mealy, Pymoo) – являются специальными библиотеками для применения метаэвристических методов, таких как генетические алгоритмы, роевая оптимизация, муравьиные колонии и прочие. Делает возможной работу с задачами большой размерности, когда стандартные методы оптимизации не позволяют получить решение.

Для дальнейшего анализа были выбраны следующие библиотеки – Mealy, Optuna, DEAP, SciPy – как предоставляющие пользователям метаэвристические алгоритмы оптимизации. Анализ библиотек в ракурсе их использования в студенческих прикладных исследованиях проводится по трем также выбранным направлениям – возможностям визуализации, работы с данными и кастомизации алгоритмов, составляющих эти библиотеки.

Анализ библиотек машинного обучения в PYTHON

В рамках данного исследования мы рассматриваем следующие показатели эффективности библиотек оптимизации языка PYTHON к использованию в студенческих прикладных исследовательских проектах:

- возможности визуализации результатов. Данный показатель направлен на оценивание того, насколько быстро студент может перейти от расчетов к анализу результатов, минуя этап отладки визуализации;
- возможности работы с данными. Данный показатель направлен на оценивание того, насколько легко студент может подключить реальные данные (из Excel, CSV) к алгоритмам оптимизации, минуя этап обработки форматов;
- возможности кастомизации алгоритмов, содержащихся в библиотеке. Показатель должен позволить оценить, насколько легко студент может модифицировать базовые алгоритмы для углубленного изучения их работы.

Перечисленные базовые показатели эффективности актуальны для студенческих исследований: простота получения графиков позволяет быстро оценить корректность выполнения задачи, а

также наглядно иллюстрирует результаты работы алгоритма, удобство работы с данными позволяет быстро осуществлять загрузку данных для последующего анализа, без задержек на этапе отладки программы, возможность кастомизации алгоритмов библиотеки также важна, поскольку зачастую прикладное исследование подразумевает внесение изменения в базовый алгоритм – как, например, это происходит при интеграции дарвиновской и ламарковской эволюционных теорий, когда в основной жизненный цикл поколения особей внедряются циклы локального поиска.

Каждый из перечисленных базовых показателей эффективности библиотек в PYTHON обобщает подмножество критериев второго уровня, которые могут быть представлены в формализованном виде.

Количественные значения оценок по каждому показателю присваивались на основании анкетирования двух групп учащихся 2-го и 3-го курсов, численностью по 20 человек, с учетом возможности оценивания библиотек PYTHON по перечисленным критериям рядом целых чисел из интервала [0–5]. Модальные значения распределений оценок, полученных в ходе анкетирования, были использованы в качестве представительных показателей для характеристики библиотек.

Возможности визуализации

Рассмотрим простые критерии, по которым были получены оценки. В качестве примерных задач для решения были взяты задачи построения расписаний для параллельных независимых машин с использованием эволюционных алгоритмов.

1. Наличие встроенных инструментов визуализации.

Оценка:

5 баллов – в библиотеке представлены готовые процедуры для построения графиков значений функций;

3 балла – требуется минимальная настройка (1–2 параметра);

1 балл – нет встроенных инструментов, требуется «ручная» реализация с использованием `matplotlib`.

2. Время построения графика средствами библиотеки.

Измеряется для графика сходимости с 1000 точками (100 эпох × 10 прогонов).

Среднее значение из 5 запусков на системе: Windows 11, Intel i5-12450H, 16 ГБ RAM.

3. Сложность реализации и освоения учащимися.

1 балл: 1–2 строки кода, нет зависимостей от других библиотек;

3 балла: 3–5 строк кода, требуется установка 1 доп. Библиотеки;

5 баллов: 10+ строк кода, требуется знание `matplotlib/seaborn`.

Таблица 1

Критерии оценивания
возможностей визуализации программных библиотек

Библио-тека	Наличие инструментов	Типы графиков	Время построения (сек)	Сложность для студента
Mealru	Полная поддержка	Сходимость алгоритма, распределение работ по машинам, 3D-траектории	0,005	1
Optuna	Через Plotly	Сходимость, важность параметров	0,013	3
DEAP	Нет	Требуется matplotlib	0,014	5
SciPy	Нет	Требуется matplotlib	0,004	5

Полученные результаты демонстрируют критическую разницу в сложности использования библиотек при работе со студентами. Хотя время построения графиков у всех библиотек достаточно низкое (0,004–0,014 сек), оценки учащихся таковы, что наиболее предпочтительной оказывается библиотека Mealru.

Mealru обеспечивает оптимальный баланс: встроенные инструменты для визуализации сходимости, распределения решений и 3D-траекторий позволяют студенту перейти от теоретических знаний к практическому анализу результатов с незначительными временными затратами. Для визуализации требуется всего 1–2 строки кода без дополнительных зависимостей.

В то же время библиотеки DEAP и SciPy, несмотря на высокую производительность при построении графиков, требуют знание matplotlib и написания 10+ строк кода для базовой визуализации. Это является причиной необходимости тратить время на отладку визуализации.

В целом в контексте простоты и удобства перехода от изучения алгоритмов к их реализации Mealru является оптимальным решением в задачах обучения студентов, равно как и в использовании этой библиотеки при реализации прикладных исследовательских проектов, позволяя в некоторой степени нивелировать дефицит компетенций. Ниже приводится пример кода с использованием библиотеки Mealru:

```
plt.plot(data, 'b-', linewidth=2)
plt.xlabel("Iteration", fontsize=12)
```

```
plt.ylabel("Fitness", fontsize=12)
plt.title("PSO Convergence (Mealpy)", fontsize=14)
plt.grid(True, linestyle="--", alpha=0.7)
plt.savefig(str(results_dir / "mealpy_convergence.png"), dpi=150, bbox_
inches='tight').
```

При этом пример с использованием библиотеки DEAP, реализующий аналогичную задачу, будет иметь следующий вид:

```
plt.figure(figsize=(8, 5))
plt.plot(range(len(data)), data, "b-", linewidth=2, label="Best Fitness")
plt.xlabel("Generation", fontsize=12)
plt.ylabel("Fitness", fontsize=12)
plt.title("GA Convergence (DEAP)", fontsize=14)
plt.legend(fontsize=10)
plt.grid(True, linestyle="--", alpha=0.7)
plt.savefig(str(results_dir / "deap_convergence.png"), dpi=150, bbox_
inches='tight')
plt.close('all')
```

Возможности работы с данными

При оценивании возможностей работы с данными выбранных библиотек языка PYTHON использовались следующие критерии и количественные оценки.

1. Поддержка форматов данных.
 - 5 баллов: Встроенная загрузка CSV, Excel (.xlsx), JSON без pandas;
 - 3 балла: Загрузка через pandas в 1 строку кода;
 - 1 балл: Требуется ручной парсинг файлов.
2. Время загрузки данных.
 - Измеряется для файла с 10 000 строк и 5 столбцами (реалистичный размер для учебных задач).
 - Среднее из 5 запусков на системе: Windows 11, Intel i5-1235U, 16 ГБ RAM.
3. Сложность для студента.
 - 1 балл: 1 строка кода, нет предварительной обработки;
 - 3 балла: 2–3 строки кода, требуется преобразование типов;
 - 5 баллов: 5+ строк кода, ручная обработка ошибок.

Таблица 2

Критерии оценивания
возможностей работы с данными программных библиотек

Библио-тека	Поддержка форматов	Время загрузки 10 000 строк	Сложность для студента	Строк кода
Mealpy	CSV, Excel, JSON	0,264	3	3
Optuna	CSV (через pandas)	0,009	3	3
DEAP	CSV (через numpy)	0,012	4	5
SciPy	CSV (ручная обработка)	0,018	5	7

Результаты тестирования выявляют принципиальные различия в подходах библиотек к работе с данными. Optuna демонстрирует минимальное время загрузки данных (0,009 сек), несмотря на использование внешней зависимости pandas. Это позволяет студентам быстрее получать результаты и проводить больше экспериментов в рамках аудиторного занятия.

Mealpy, несмотря на формальную поддержку нескольких форматов (CSV, Excel, JSON), показывает наименьшую производительность (0,264 сек). Тем не менее удобство использования данной библиотеки объясняется наличием единой парадигмы работы с разными форматами данных. DEAP и SciPy демонстрируют нарастающую сложность реализации: DEAP требует 5 строк кода и знания numpy (сложность 4 балла), SciPy – 7 строк кода и ручной обработки данных (сложность 5 баллов).

В итоге рассмотренные библиотеки, даже при наличии формальной поддержки различных форматов данных, не предоставляют специализированных инструментов, оптимизированных для учебных задач. Для повышения их эффективности с точки зрения простоты освоения в учебном процессе требуется разработка учебных шаблонов с заранее настроенной загрузкой данных, что позволит студентам сосредоточиться на изучении алгоритмов, а не на технических деталях обработки форматов. Ниже приведены лучший пример кода (библиотека Optuna) и худший пример (библиотека SciPy).

Лучший пример (Optuna):

```
import pandas as pd
df = pd.read_csv(csv_path)
study = optuna.create_study(direction="maximize")
```

Худший пример (SciPy):

```
import numpy as np
with open(csv_path, 'r') as f:
    lines = f.readlines()[1:]
    data = np.array([line.strip().split(',') for line in lines], dtype=float)
result = minimize(lambda x: np.sum(x**2), np.zeros(5)).
```

Возможности кастомизации алгоритмов

Вопросы удобства и в целом возможностей кастомизации алгоритмов актуальны в том случае, когда в рамках проекта требуется изменение базовых алгоритмов, в том числе алгоритмов оптимизации и машинного обучения, входящих в состав библиотек. Оценивание производилось по следующим критериям:

1. Глубина кастомизации.

5 баллов: Изменение внутренней логики через схему наследования классов.

3 балла: Настройка параметров через конструктор.

1 балл: Только изменение внешних параметров (размер популяции).

2. Количество строк кода.

Измерение было проведено для задачи: изменить функцию мутации в генетическом алгоритме с замены битов на инверсию сегмента.

3. Сложность для студента.

1 балл: 3–5 строк кода, понятная документация;

3 балла: 6–10 строк кода, требуется анализ примеров;

5 баллов: 15+ строк кода, требуется изучение исходного кода.

Таблица 3

Критерии оценивания возможностей кастомизации алгоритмов программных библиотек

Библиотека	Глубина кастомизации	Строк для изменения мутации	Сложность для студента
Mealpy	Наследование классов	8	3
Optuna	Callback-функции	18	4
DEAP	Полная свобода	35	5
SciPy	Параметры мутации	12	2

Mealpy, несмотря на относительно небольшой объем кода (8 строк) и приемлемую сложность (3/5), не обеспечивает значительного преимущества перед другими библиотеками. SciPy имеет наименьшую сложность кастомизации (2/5), что делает ее потенциально наиболее доступной для начинающих студентов, однако ограниченные возможности модификации алгоритма серьезно ограничивают ее учебную ценность.

DEAP, предоставляя наибольшую свободу кастомизации («Полная свобода»), требует максимальных усилий от студента (35 строк кода, сложность 5/5), что создает непреодолимый барьер для начинающих. Ortpna занимает промежуточное положение, но ее сложная архитектура и необходимость понимания callback-механизмов (18 строк кода) также ограничивают педагогическую эффективность.

Пример кастомизации с использованием библиотеки Mealpy приведен ниже (лучший пример).

```
from mealpy import FloatVar
from mealpy.evolutionary_based import GA
import numpy as np
class CustomGA(GA.OriginalGA):
    def mutation__(self, position):
        child = position.copy()
        idx1, idx2 = sorted(np.random.choice(len(child),
        2, replace=False))
        child[idx1:idx2] = child[idx1:idx2][::-1]
        return child
```

Пример кастомизации с использованием библиотеки DEAP также приведен ниже (худший пример).

```
def custom_mutation(individual):
    idx1, idx2 = sorted(random.sample(range(len(individual)), 2))
    segment = individual[idx1:idx2]
    segment.reverse()
    individual[idx1:idx2] = segment
    return individual,
toolbox.register("mutate", custom_mutation)
toolbox.register("select", tools.selTournament, tournsize=3)
```

Экспериментальное сравнение реализаций процедур в рамках использования библиотек

В качестве примера сравнения реализаций использования библиотек PYTHON были выбраны Meaipy и DEAP с примером визуализации тренда изменения значений целевой функции в задаче построения расписания для независимых работ на параллельных независимых машинах. Библиотека Meaipy позволяет реализовать вывод графика исключительно внутренними средствами визуализации, в то время как для визуализации расчетов, выполненных в библиотеке DEAP, требуется подключение функций matplotlib. Рассмотрим получаемый график (рис. 1)

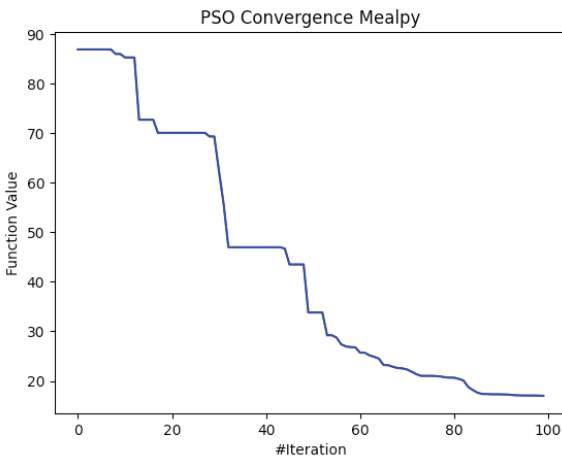


Рис. 1. Пример визуализации тренда изменения значений целевой функции в задаче построения расписания для независимых работ на параллельных независимых машинах

Для его реализации требуется программный код на meaipy вида, как представлено в листинге ниже:

```
from meaipy.utils.visualize import export_convergence_chart
def test_meaipy_viz(data):
    times = []
    for _ in range(5):
        start = time.time()
```

```
        export_convergence_chart(data, title="PSO Convergence
Mealpy", filename="convergence")
        times.append(time.time() – start)
        avg_time = np.mean(times)
        return avg_time
```

Для получения аналогичного графика при помощи средств библиотеки DEAP используется следующий фрагмент программного кода.

```
def test_deap_viz(data):
    times = []
    for _ in range(5):
        start = time.time()
        plt.plot(data, label="Best fitness")
        plt.xlabel("Generation")
        plt.ylabel("Fitness")
        plt.title("")
        plt.legend()
        plt.grid(True)
        times.append(time.time() – start)
        plt.close('all')
    avg_time = np.mean(times)
    # Сохраняем итоговый график
    plt.figure(figsize=(8, 5))
    plt.plot(range(len(data)), data, "b-", linewidth=2, label="Best Fitness")
    plt.xlabel("Generation", fontsize=12)
    plt.ylabel("Fitness", fontsize=12)
    plt.title("GA Convergence (DEAP)", fontsize=14)
    plt.legend(fontsize=10)
    plt.grid(True, linestyle="--", alpha=0.7)
    plt.savefig(str(results_dir / "deap_convergence.png"), dpi=150, bbox_
inches='tight')
    plt.close('all')
    return avg_time
```

Таким образом, на наглядном примере визуализации результатов работы алгоритма видно, насколько библиотека mealpy будет выгодна в контексте студенческих прикладных исследований: с меньшей трудоемкостью получен аналогичный результат, визуализация поведения алгоритма оптимизации.

Заключение

Построение систем искусственного интеллекта, использование моделей и методов машинного обучения являются приоритетными направлениями науки в настоящее время. Тесная интеграция ИИ и методов оптимизации актуализирует использование и разработку оптимизационных алгоритмов.

В то же время растет количество прецедентов разработки систем ИИ в рамках студенческих прикладных исследовательских проектов. В данной области также существует ряд проблем, важными из которых представляются недостаток компетенций и мотивации у студентов для работы над проектами. По этой причине определенный научный интерес представляет анализ библиотек языка программирования PYTHON, часто используемого в проектных исследованиях, в ракурсе удобства его использования студентами.

Таким образом, в ходе проведенного исследования показано, что библиотеки PYTHON обладают различной эффективностью и представляют удобный инструментарий для реализации прикладных исследований. Рациональный выбор инструментария представляется целесообразным как с точки зрения снижения временных затрат на реализацию прикладных исследований, так и с точки зрения мотивационной поддержки участников исследовательских проектов.

Литература

- Дубровская 2020 – Дубровская Е.Н., Чуланова О.Л., Курпиянова Е.В. Мотивация преподавателей-наставников и студентов в проектной деятельности (на примере проекта «Сквозные компетенции проектной деятельности» Сургут) // *Материалы Ивановских чтений*. 2020. № S4 (31). С. 91–97.
- Клименко, Ельмекеев 2025 – Клименко А.Б., Ельмекеев М.А. Анализ ресурсной эффективности эволюционных принципов Ламарка при решении задач планирования вычислений // XVIII Всероссийская мультikonференция по проблемам управления (МКПУ–2025): материалы мультikonференции (Тула, 15 сентября – 20 сентября 2025 г.). Т. 2: Управление в распределенных и сетевых системах (УРСС – 2025) / Под ред. И.А. Каляева. Тула: ТГУ, 2025. С. 207–210
- Рудник 2025 – Абашкин В.Л., Абдрахманова Г.И. и др. Искусственный интеллект в России: разработка и применение / Под ред. Л.М. Гохберга, П.Б. Рудника, Г.И. Абдрахмановой. М.: НИУ ВШЭ, 2025. 86 с.
- Самарина 2023 – Самарина А.Е., Бояринов Д.А. Нейросети для генерации изображений: педагогический потенциал в высшем образовании // *Научно-методический электронный журнал «Концепт»*. 2023. № 11. С. 161–179.

- Klimenko 2025 – *Klimenko A., Elmekeev M.* Case study of Lamarckian and Baldwin evolution principles application to the computations planning in resource-constrained ad-hoc networks // 18th International Conference on Management of Large-Scale System Development (MLSD). New York: IEEE, 2025. P. 1–6.
- Nieminen 2025 – *Nieminen N., Reunanen T.* Combining AI tools, low-code platforms, and product development in ICT education: A reflective study on educational and practical outcomes // *Human Factors, Business Management and Society*. 2025. Vol. 176. P. 228–241.
- Pecore 2015 – *Pecore J.L.* From Kilpatrick’s Project Method to Project-Based Learning // *International Handbook of Progressive Education*. New York, NY, 2015. P. 155–171.

References

- Arnautov, A.D. and Ryabov, O.N. (2017), “Potential of Student Project Activity in Developing Their Competence”, *Sovremennye naukoemkie tekhnologii*, no. 7, pp. 87–91.
- Dubrovskaja, E.N., Chulanova, O.L. and Kupriianova, E.V. (2020), “Motivation of Mentors and Students in Project Work (Based on the Example of the Project ‘Cross-Cutting Competences of Project Work’ Surgut)”, *Materialy Ivanovskih chtenii*, no. S4 (31), pp. 91–97.
- Klimenko, A.B. and Elmekeev, M.A. (2025), “Resource-Efficiency Analysis of Evolutionary Principles of Lamarck in Solving Computational Planning Problems”, in Kalyaeva, I.A. (ed.), *XVIII Vserossiiskaya mul'tikonferentsiya po problemam upravleniya (MKPU–2025): materialy mul'tikonferentsii (Tula, Sentyabr' 15–20, 2025)*, t. 2. *Upravlenie v raspredelennykh i setevykh sistemah (URSS–2025)* [28th All Russian Multi-conference on Management Issues (MCPU-2025): proceedings of the multi-conference (Tula, September 15–20, 2025), vol. 2: Management in Distributed and Networked Systems (URSS – 2025)], TSU, Tula, Russia, pp. 207–210.
- Klimenko, A. and Elmekeev, M. (2025), “Case study of Lamarckian and Baldwin evolution principles application to the computations planning in resource-constrained ad-hoc networks”, *Proceedings of the 18th International Conference on Management of Large-Scale System Development (MLSD)*, IEEE, New York, USA, pp. 1–6.
- Nieminen, N. and Reunanen, T. (2025), “Combining AI tools, low-code platforms, and product development in ICT education: A reflective study on educational and practical outcomes”, *Human Factors, Business Management and Society*, vol. 176, pp. 228–241.
- Pecore, J.L. (2015), “From Kilpatrick’s Project Method to Project-Based Learning”, *International Handbook of Progressive Education*, New York, NY, USA, pp. 155–171.
- Samarina, A.E. and Boyarinov, D.A. (2023), “Neural Networks for Image Generation: Pedagogical Potential in Higher Education”, *Scientific-methodological electronic journal “Koncept”*, no. 11, pp. 161–179.

Информация об авторах

Анна Б. Клименко, кандидат технических наук, доцент, Российский государственный гуманитарный университет, Москва, Россия; 125047, Россия, Москва, Миусская пл., д. 6, стр. 6; anna_klimenko@mail.ru

Вадим В. Жепан, студент, Российский государственный гуманитарный университет, Москва, Россия; 125047, Россия, Москва, Миусская пл., д. 6, стр. 6.

Information about the authors

Anna B. Klimenko, Cand. of Sci. (Computer Science), associate professor, Russian State University for the Humanities, Moscow, Russia; 6-6, Miusskaya Sq., Moscow, 125047, Russia; anna_klimenko@mail.ru.

Vadim V. Zhepan, student, Russian State University for the Humanities, Moscow, Russia; 6-6, Miusskaya Sq., Moscow, 125047, Russia.

Разработка метода классификации и временной локализации поезда на основе нейронных сетей

Никита А. Котляров

*Московский государственный технический университет
им. Н.Э. Баумана, Москва, Россия, nikita_kotlyarov2002@mail.ru*

Кирилл Л. Тассов

*Московский государственный технический университет
им. Н.Э. Баумана, Москва, Россия, ktassov@bmstu.ru*

Аннотация. Задача выделения и классификации объектов из окружающего шума всегда была актуальна. Один из возможных подходов выделения звуков поездов из общей аудиозаписи – использование нейронных сетей, которые могут выполнять предварительную обработку звуковой дорожки, решать задачи детектирования и классификации. Известные методы для анализа звуковых паттернов используют рекуррентные нейронные сети. В статье описывается метод, основанный на применении сети с долгой кратковременной памятью.

Зачастую требуется дополнительное подтверждение местоположения поезда, когда другие распространенные методы мониторинга оказываются неэффективными или требовательными к дорогостоящему оборудованию. Так, GPS не работает во множестве мест рядом с железными дорогами из-за их стратегической важности, а автоматическое слежение по камерам требует четкой картинки, что слишком дорого обеспечить для каждой станции. В то же время мониторинг по аудиосигналу, как показало исследование, не предъявляет таких требований к качеству и цене. Благодаря этому возникает возможность мониторинга положения поезда дополнительным методом.

Целью статьи является разработка метода классификации сигналов железнодорожного шума по признаку принадлежности к типу поезда и определения временных меток. В статье изучаются различные нейронные сети и их комбинации с целью выявить наиболее оптимальные архитектуру и параметры в рамках поставленной задачи.

Было установлено, что наиболее точная классификация производится с помощью комбинации рекуррентной нейронной сети с долгой кратковременной памятью и сверточной нейронной сети.

© Котляров Н.А., Тассов К.Л., 2026

Ключевые слова: детектирование звуков, рекуррентные нейронные сети, классификация, сверточные нейронные сети, LSTM

Для цитирования: Котляров Н.А., Тассов К.Л. Разработка метода классификации и временной локализации поезда на основе нейронных сетей // Вестник РГГУ. Серия «Информатика. Информационная безопасность. Математика». 2026. № 1. С. 55–70. DOI: 10.28995/2686-679X-2026-1-55-70

Development of a method for classification and temporal localization of trains based on neural networks

Nikita A. Kotlyarov

*Bauman Moscow State Technical University,
Moscow, Russia, nikita_kotlyarov2002@mail.ru*

Kirill L. Tassov

*Bauman Moscow State Technical University,
Moscow, Russia, ktassov@bmstu.ru*

Abstract. The issue of identifying and classifying objects from ambient noise has always been relevant. One possible approach to extracting train sounds from a general audio recording is the use of neural networks, which can pre-process the audio track and perform detection and classification tasks. Known methods for analyzing sound patterns employ recurrent neural networks. This article describes a method based on a long short-term memory network.

Additional confirmation of a train's location is often required when other common monitoring methods prove ineffective or require expensive equipment. For example, GPS does not work in many locations near railways due to their strategic importance, and automatic camera tracking requires a clear image, which is too expensive to provide for each station. However, as research has shown, audio signal monitoring does not impose such quality and cost requirements. This opens the possibility of monitoring train positions using an additional method.

The aim of this article is to develop a method for classifying railway noise signals based on train type and determining timestamps. This article examines various neural networks and their combinations to identify the most optimal architecture and parameters for the task at hand.

It was found that the most accurate classification is achieved using a combination of a recurrent neural network with long short-term memory and a convolutional neural network.

Keywords: sound detection, recurrent neural networks, classification, convolutional neural networks, LSTM

For citations: Kotlyarov, N.A. and Tassov, K.L. (2026), "Development of a method for classification and temporal localization of trains based on neural networks", *RSUH/RGGU Bulletin. "Information Science. Information Security. Mathematics" Series*, no. 1, pp. 55–70, DOI: 10.28995/2686-679X-2026-1-55-70

Введение

Классификация источников звука и определения временных рамок, в которых звук является основной задачей при анализе звука, играет значительную роль в сфере вспомогательных систем контроля. В качестве объектов классификации может рассматриваться человеческая речь, индустриальные и природные звуки. Результатом решения задачи выделения является информация об источнике шума, полученная из аудиозаписи.

Распознавание типа проезжающих поездов по аудиозаписи и временная локализация могут служить в качестве дополнительной системе контроля над местонахождением железнодорожных составов в случае невозможности использования классических решений, таких как GPS и спутниковая связь с машинистом. Использование аудиозаписи позволяет осуществить локализацию поезда при помощи небольших вычислительных средств и недорогого оборудования, сравнивая с видеоконтролем.

Были выделены три класса поездов: пассажирский состав, товарный и электричка. Подобное деление было использовано из-за отсутствия возможности собрать достаточно данных для остальных типов железнодорожного транспорта.

Существующие решения

Существующие задачи по классификации звуков окружающей среды схожи с темой этой статьи. Для них используются различные решения: в статье [Bansal 2024] исследуется сверточная рекуррентная нейронная сеть для классификации звуков окружающей среды. При этом определение временных рамок события не производится. В статье [Пикалёв 2019] приведено сочетание нейронной сети с временной задержкой и двунаправленной долгой кратковременной нейронной сети. В статьях [Zhang 2024] и [Petmezas 2022] производится комбинация сверточной нейронной сети и долгой

кратковременной нейронной сети. Преимущество нейронной сети с временной задержкой – это возможность выделить множество классов в аудиозаписи, однако эти классы должны уместиться в небольшие сегменты аудиозаписи. В поставленной задаче сигналы длительные и задействуют одинаковые частоты, что делает задачу трудновыполнимой для представленных архитектур.

В известных работах, находящихся в открытом доступе, исследуются способы классификации звуков с помощью нескольких нейронных сетей, однако задача выделения временных рамок является новой для данной области.

Постановка задачи

Целью статьи является обоснование методики распознавания и классификации поездов на аудиозаписях с использованием нейронной сети долгой кратковременной памяти. Диаграмма функциональной модели представлена на рис. 1:

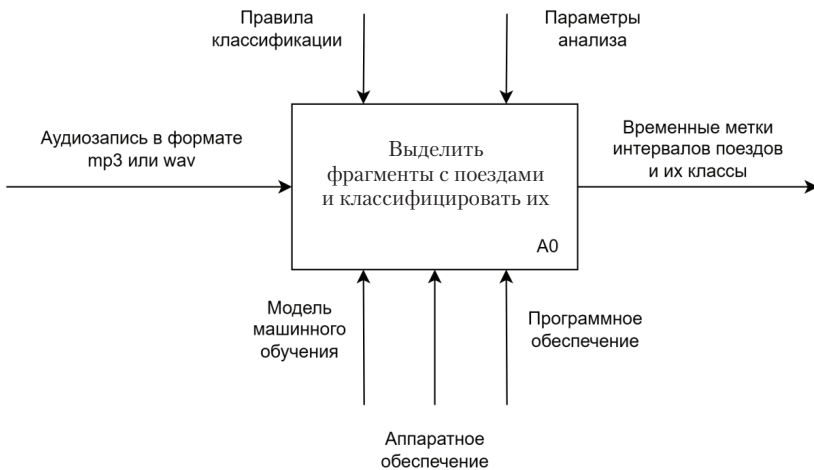


Рис. 1. Диаграмма верхнего уровня. Постановка задачи

На вход системы распознавания подается аудиозапись, на которой записаны звуки проезжающих поездов различных классов. Результатом работы системы является список временных меток и описание класса поезда, соответствующего временной метке.

Разрабатываемый алгоритм распознавания должен быть устойчив к шумам и помехам.

На входную аудиозапись накладываются следующие ограничения:

- звуки поездов не накладываются друг на друга;
- отношение сигнал/шум больше 0 дБ, т. е. уровень сигнала превышает уровень шума.

Ставится задача исследовать различные нейронные сети и их комбинации для создания архитектуры, способной проводить наиболее точную классификацию.

Данные для обучения

Обучение нейронной сети проводилось на наборе данных, который включал 121 час аудиозаписей. Набор состоял из 1583 записей проходящих поездов следующего распределения:

- товарные поезда: 218;
- пассажирские поезда: 673;
- электропоезда: 692.

Исходная выборка была разделена на обучающую и тестовую. Обучающая выборка содержит 1055 событий, а тестовая – 528.

Показатели точности

Для оценки точности во время обучения использовалась метрика ассигасу (1). Эта метрика показывает количество верно указанных классов. Для оценки точности классификации использовались средние значения *precision* (3) и *recall* (4) по всем классам [Yuer 2023]. Эти метрики для каждого из классов показывают, какая доля объектов, отнесенных к конкретному классу, действительно ему принадлежит, и какая доля объектов определенного класса была обнаружена моделью. Также использовалась метрика *f1-score* (5), которая является средним гармоническим *precision* (3) и *recall* (4).

Для оценки точности была использована метрика *Assurasy*:

$$\text{Assurasy} = \frac{TP+TN}{TP+TN+FP+FN}, \quad (1)$$

где *TP* – число элементов, которые относятся к выбранному классу и были верно предсказаны моделью, *FP* – число элементов, которые не относятся к выбранному классу, но были отнесены моделью к нему, *FN* – число элементов, которые принадлежат выбранному классу, но

были отнесены моделью к другому, а TN – число элементов, которые не были отнесены к выбранному классу, что является корректным.

Для расчета функции потери использовалась функция кросс-энтропии:

$$L_{total} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(p_{i,c}), \quad (2)$$

где C – количество классов, N – количество объектов, $y_{i,c}$ – бинарный идентификатор (1 – при правильном предсказании, 0 – иначе), $p_{i,c}$ – предсказанная вероятность выбранного класса.

Для расчета precision используется следующее соотношение:

$$Precision = \frac{TP}{TP+FP}. \quad (3)$$

Для расчета recall используется следующее соотношение:

$$Recall = \frac{TP}{TP+FN}. \quad (4)$$

$F1score$ является средним гармоническим precision (3) и recall (4):

$$F1score = 2 \frac{Precision * Recall}{Precision + Recall}. \quad (5)$$

Описание метода

Существуют различные рекуррентные нейронные сети, ориентированные на временные ряды. Сеть Элмана – плохо обучается на длинных последовательностях, из-за чего для этой задачи не подходит. Длинная кратковременная память – хорошо справляется с сигналами переменной длины и контекстом, растянутым во времени. Управляемый рекуррентный блок – быстро обучается, однако имеет худшую точность по сравнению с LSTM – нейронная сеть с долгой кратковременной памятью, если зависимости длинные. Двухнаправленная LSTM – имеет высокую точность, однако не подходит для работы в реальном времени, так как требует весь сигнал заранее. Таким образом, для поставленной задачи подходит глубокая память, представителем которой является LSTM.

На вход алгоритм принимает аудиозапись в формате MP3 или WAV. Разработанный алгоритм представляет собой последовательность действий:

1. В аудиозаписи выделяется частотная полоса от 20 до 4000 Гц.
2. Полученные данные разбиваются на сегменты по 5 секунд с перекрытием в 50%.

3. Проводится классификация отрезков.

4. Из размеченных отрезков извлекаются временные рамки.

Результатом работы алгоритма является список временных рамок, на которых были найдены поезда и соответствующие классы.

Аудиозапись переводится в формат WAV, обрезаются не являющиеся значимыми частоты, после чего данные передаются сети долгой кратковременной памяти. Как видно на рис. 2, удаление не значимых частот приводит к значительному увеличению качества классификации:



Рис. 2. Сравнение результатов с использованием предобработки и без использования

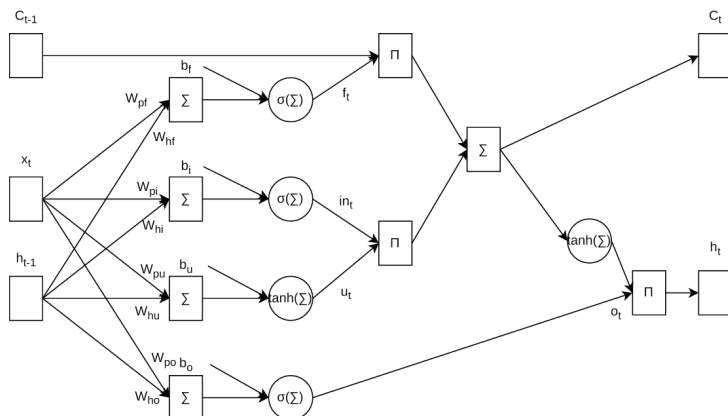


Рис. 3. Структура используемой LSTM

Архитектура LSTM отличается от классической RNN [Yu 2019] и представлена на рис. 3:

Математически используемую модель [Duan 2021] можно представить как:

$$f_t = \sigma(W_{hf} \cdot h_{t-1} + W_{pf} \cdot X_t + b_{fo}), \quad (6)$$

$$in_t = \sigma(W_{hi} \cdot h_{t-1} + W_{pi} \cdot X_t + b_{in}), \quad (7)$$

$$u_t = \tanh(W_{hu} \cdot h_{t-1} + W_{pu} \cdot X_t + b_u), \quad (8)$$

$$C_t = f_t \odot C_{t-1} + in_t \odot u_t, \quad (9)$$

$$o_t = \sigma(W_{ho} \cdot h_{t-1} + W_{po} \cdot X_t + b_o), \quad (10)$$

$$h_t = o_t \odot \tanh(C_t), \quad (11)$$

где in_t , f_t , o_t – ворота входа, утраты и выхода соответственно; W_{hf} , W_{pf} , W_{hi} , W_{pi} , W_{pu} , W_{hu} , W_{po} – веса; b_{fo} , b_{in} , b_u , b_o – коэффициенты биаса; u_t – вектор новых возможных значений, которые могут быть добавлены в состояние сети; h_{t-1} и h_t – предыдущее и текущее скрытое состояние; σ – сигмоида, $\frac{1}{1+e^{-x}}$. X_t – входные данные в момент времени t . Размером входного вектора является матрица 13×156 , что соответствует 5 секундам входной аудиозаписи, где 13 – разбиение по частотным полосам.

Размер скользящего окна сильно влияет на точность классификации и размер нейронной сети:

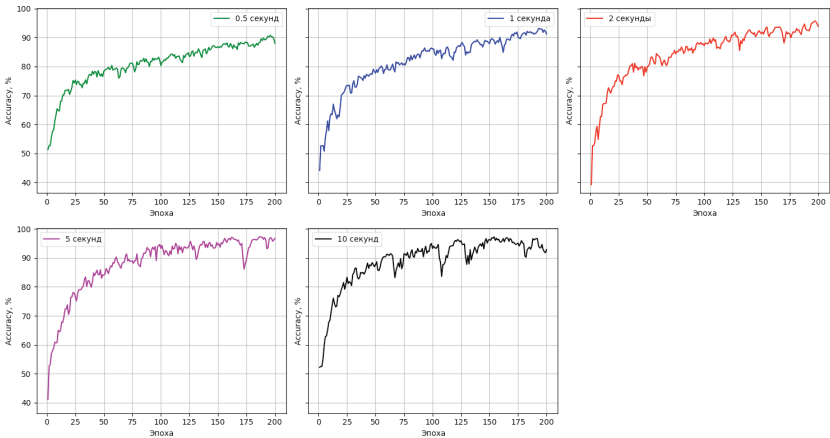


Рис. 4. Сравнение точности классификации от размера скользящего окна

Как видно из результатов исследования (см. рис. 4), оптимальным размером скользящего окна является 5 секунд – больший размер не увеличивает точность, а при меньшем она падает.

Была исследована зависимость точности классификации от метода градиентного спуска:

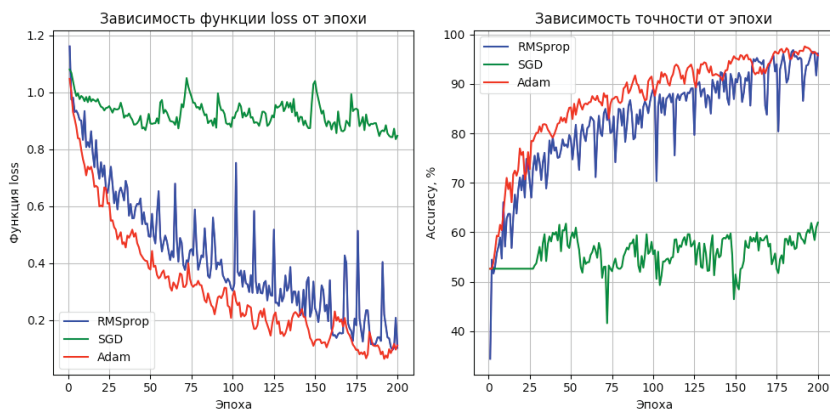


Рис. 5. Сравнение точности классификации от метода градиентного спуска

Были исследованы методы Adam, RMSprop и SGD. Как видно на рис. 5, Adam является лучшим выбором в рамках представленной задачи.

Сверточная нейронная сеть

Была исследована способность сверточной нейронной сети справляться с классификацией акустических данных. Была использована простейшая сверточная сеть с тремя ядрами свертки. На вход принимается спектрограмма 128 на 128 пикселей и с каждым слоем размерность уменьшается в 4 раза. В качестве классификатора используется адаптивное усреднение.

Как видно на рис. 6, точность классификации сверточной нейронной сети уступает LSTM: максимальная точность CNN – 75%, у LSTM – 98%.

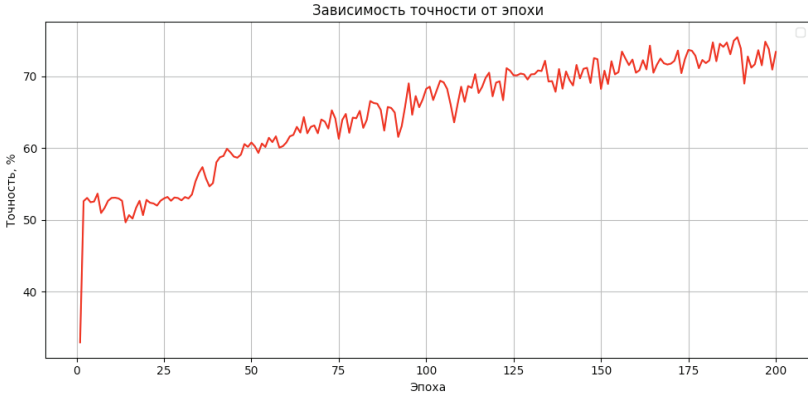


Рис. 6. Точность классификации в зависимости от эпохи

Исследование

Была исследована зависимость точности классификации от эпохи при разных количествах слоев нейронной сети. Итоговая точность классификации на тестовой выборке составила 0,97, что соответствует 186 эпохе (см. рис. 7):

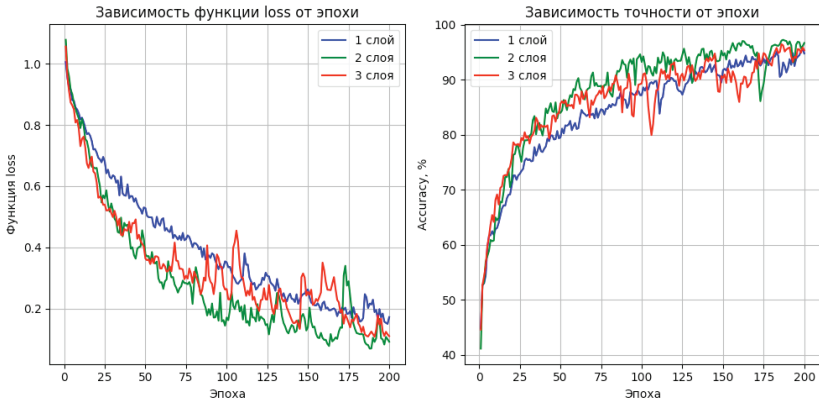


Рис. 7. Точность классификации в зависимости от эпохи

Таблица 1

Точность для LSTM с 1 слоем

	precision	recall	f1-score
Электрички	0,80	0,78	0,79
Пассажирские поезда	0,82	0,90	0,86
Грузовые поезда	0,89	0,62	0,73
Среднее	0,84	0,77	0,79
Взвешенное среднее	0,82	0,82	0,82

Таблица 2

Точность для LSTM с 2 слоями

	precision	recall	f1-score
Электрички	0,96	0,99	0,97
Пассажирские поезда	0,99	0,97	0,98
Грузовые поезда	0,99	0,99	0,99
Среднее	0,98	0,98	0,98
Взвешенное среднее	0,98	0,98	0,98

Таблица 3

Точность для LSTM с 3 слоями

	precision	recall	f1-score
Электрички	0,85	0,83	0,84
Пассажирские поезда	0,87	0,90	0,88
Грузовые поезда	0,83	0,75	0,79
Среднее	0,85	0,83	0,84
Взвешенное среднее	0,86	0,86	0,86

Была исследована зависимость точности классификации при разных весах в параллельном ансамбле LSTM и CNN. Итоговая точность классификации на тестовой выборке составила 0,99.

Таблица 4

Точность для 0.4 LSTM и 0.6 CNN

	precision	recall	f1-score
Электрички	0,78	0,76	0,77
Пассажирские поезда	0,83	0,89	0,85
Грузовые поезда	0,86	0,54	0,66
Среднее	0,82	0,73	0,76
Взвешенное среднее	0,81	0,78	0,79

Таблица 5

Точность для 0.5 LSTM и 0.5 CNN

	precision	recall	f1-score
Электрички	0,87	0,79	0,83
Пассажирские поезда	0,88	0,89	0,88
Грузовые поезда	0,80	0,77	0,78
Среднее	0,85	0,81	0,83
Взвешенное среднее	0,86	0,82	0,85

Таблица 6

Точность для 0.6 LSTM и 0.4 CNN

	precision	recall	f1-score
Электрички	0,98	0,99	0,98
Пассажирские поезда	0,99	0,99	0,99
Грузовые поезда	0,99	0,99	0,99
Среднее	0,99	0,99	0,99
Взвешенное среднее	0,99	0,99	0,99

Таким образом, при использовании ансамбля незначительно повышается точность.

Обсуждение полученных результатов

Как видно из рис. 6, наилучший результат показывает двухслойная LSTM. У однослойной модели недостаточное количество весов, что делает обучение медленнее и менее эффективно. При этом трехслойная модель показала более быстрое обучение на ранних этапах, но при этом на поздних этапах происходило сильное переобучение, что привело к просадкам точности и медленному восстановлению.

Однако даже подходящая двухслойная модель начала переобучаться на поздних эпохах. Этого можно избежать, увеличив датасет прямым способом – собрать больше аудиозаписей, и/или увеличить с помощью добавление шума, сдвига по времени или сдвига высоты звука [Maguolo 2025].

При использовании ансамбля с CNN полученная точность близится к 1, однако при этом происходит заметное замедление работы сети.

Высокая точность на тестовом наборе дает уверенность в надежности и качестве модели и показывает, что она действительно способна правильно классифицировать звуки проезжающих поездов, которых не было в обучающем наборе. Полученные результаты свидетельствуют о практической применимости разработанного метода.

Заключение

В рамках данного исследования была поставлена задача разработки метода классификации сигналов железнодорожного шума по признаку принадлежности к типу поезда и определения временных меток. Проведенные эксперименты позволили установить, что наилучшей архитектурой для этой задачи является ансамбль двухслойной LSTM и CNN.

Разработанный метод позволяет не только выделять техногенные шумы из аудиопотока, но и определять их временные границы, что необходимо для оценки соответствия санитарным нормам. Результаты работы демонстрируют, что комбинация двухслойной модели нейронной сети с долгой кратковременной памятью с сверточной нейронной сетью позволяет с высокой точностью решать задачу классификации звуков, отделяя шумы поездов от других источников, таких как речь или природные звуки. При этом ключевыми факторами, влияющими на точность, являются качество обучающих данных, выбор акустических признаков и оптимизация параметров модели.

Полученные результаты могут быть применены в системах экологического мониторинга, автоматического контроля шума вблизи железных дорог и других задачах, требующих анализа звуковой среды. Дальнейшие исследования могут быть направлены на улучшение алгоритмов в условиях сильных шумовых помех, а также на разработку методов реального времени для оперативного принятия решений.

Литература

- Пикалёв 2019 – *Пикалёв Я.С., Ермоленко Т.В.* Технология повышения робастности акустической модели в задаче распознавания речи // XII мультиконференция по проблемам управления (МКПУ-2019): материалы XII мультиконференции (Дивноморское, Геленджик, 23–28 сентября 2019 г.): В 4 т. Ростов н/Д; Таганрог: Южный федеральный университет, 2019. С. 45–56.
- Bansal 2024 – *Bansal A., Garg N.K.* Robust technique for environmental sound classification using convolutional recurrent neural network // *Multimedia Tools and Applications*. 2024. Vol. 83. P. 54755–54772.
- Duan 2021 – *Duan G., Zhang S., Lu M., Okinda C., Shen M., Norton T.* Short-term feeding behaviour sound classification method for sheep using LSTM networks // *International Journal of Agricultural and Biological Engineering*. 2021. Vol. 14. No. 2. P. 43–54.
- Iyer 2024 – *Iyer G., Yao Y.J., Zhong Z.Z.* Precision-Recall Tradeoff in Algorithmic Targeting, 2024. URL: https://www.jesseyao.com/Algorithmic_Targeting.pdf (дата обращения: 04.12.2025).
- Maguolo 2025 – *Maguolo G., Paci M., Nanni L., Bonan L.* Audiogmenter: a MATLAB toolbox for audio data augmentation // *Applied Computing and Informatics*. 2025. Vol. 21 (1/2). P. 152–163.
- Petmezas 2022 – *Petmezas G., Cheimariotis G.-A., Stefanopoulos L., Rocha B., Paiva R.P., Katsaggelos A.K., Maglaveras N.* Automated Lung Sound Classification Using a Hybrid CNN-LSTM Network and Focal Loss Function // *Sensors*. 2022. Vol. 22. P. 1232.
- Yu 2019 – *Yu Y., Si X., Hu C., Zhang J.* A review of recurrent neural networks: LSTM cells and network architectures // *Neural computation*. 2019. Vol. 31 (7). P. 1235–1270.
- Yu 2023 – *Yu F., Huang J., Luo Z., Zhang L., Lu W.* An effective method for figures and tables detection in academic literature // *Information Processing & Management*. 2023. Vol. 60 (3). P. 103286.
- Zhang 2024 – *Zhang W.* CTRNet: An Automatic Modulation Recognition Based on Transformer-CNN Neural Network // *Electronics*. 2024. Vol. 13 (17). P. 3408.

References

- Bansal, A. and Garg, N.K. (2024), “Robust technique for environmental sound classification using convolutional recurrent neural network”, *Multimedia Tools and Applications*, vol. 83. pp. 54755–54772.
- Duan, G., Zhang, S., Lu, M., Okinda, C., Shen, M. and Norton, T. (2021), “Short-term feeding behaviour sound classification method for sheep using LSTM networks” *International Journal of Agricultural and Biological Engineering*, vol. 14. no. 2, pp. 43–54.
- Iyer, G., Yao, Y.J. and Zhong, Z.Z. (2024), “Precision-Recall Tradeoff in Algorithmic Targeting”, available at: https://www.jesseyao.com/Algorithmic_Targeting.pdf (Acceded 04 December 2025).
- Maguolo, G, Paci, M, Nanni, L and Bonan, L. (2025), “Audiogmenter: a MATLAB toolbox for audio data augmentation”, *Applied Computing and Informatics*, vol. 21 (1/2), pp. 152–163.
- Petmezas, G., Cheimariotis, G.-A., Stefanopoulos, L., Rocha, B., Paiva, R.P., Katsaggelos, A.K. and Maglaveras, N. (2022), “Automated Lung Sound Classification Using a Hybrid CNN-LSTM Network and Focal Loss Function”, *Sensors*, vol. 22, p. 1232.
- Pikaley, Y.S. and Ermolenko, T.V. (2019), “Technology for increasing the robustness of an acoustic model in the speech recognition problem”, *XII mul'tikonferentsiya po problemam upravleniya (MKPU-2019): materialy XII mul'tikonferentsii (Divnomorskoe, Gelendzhik, 23–28 sentyabrya 2019 g.): v 4 t.* [Multi-conference on Management Issues (MCPU-2019). Proceedings of the multi-conference (Divnomorskoe, Gelendzhik, 23–28 September 2019). In 4 vols.], Southern Federal University, Rostov-on-Don; Taganrog, Russia, pp. 45–56.
- Yu, F., Huang, J., Luo, Z., Zhang, L. and Lu, W. (2023), “An effective method for figures and tables detection in academic literature”, *Information Processing & Management*, vol. 60 (3), pp. 103286.
- Yu, Y., Si, X., Hu, C. and Zhang, J. (2019), “A review of recurrent neural networks: LSTM cells and network architectures”, *Neural computation*, vol. 31 (7), pp. 1235–1270.
- Zhang, W., Xue, K., Yao, A. and Sun, Y. (2024), “CTRNet: An Automatic Modulation Recognition Based on Transformer-CNN Neural Network”, *Electronics*, vol. 13 (17), pp. 3408.

Информация об авторах

Никита А. Котляров, студент, Московский государственный технический университет им. Н.Э. Баумана, Москва, Россия; 105005, Россия, Москва, 2-я Бауманская ул., д. 5; nikita_kotlyarov2002@mail.ru; ORCID: 0009-0004-4114-8682

Кирилл Л. Тассов, Московский государственный технический университет им. Н.Э. Баумана, Москва, Россия; 105005, Россия, Москва, 2-я Бауманская ул., д. 5; ktassov@bmstu.ru; SPIN: 1141-6778

Information about the authors

Nikita A. Kotlyarov, student, Bauman Moscow State Technical University, Moscow, Russia; bld. 5, 2nd Baumanskaya Str., Moscow, 105005, Russia; nikita_kotlyarov2002@mail.ru; ORCID: 0009-0004-4114-8682.

Kirill L. Tassov, Bauman Moscow State Technical University, Moscow, Russia; bld. 5, 2nd Baumanskaya Str., Moscow, 105005, Russia; ktassov@bmstu.ru; SPIN: 1141-6778

Концепция локального органайзера фотогалереи на основе распознавания с многофакторной фильтрацией лиц

Андрей П. Титов

*МИРЭА – Российский технологический
университет, Москва, Россия;*

*Институт кибербезопасности и цифровых технологий,
Москва, Россия, titov_and@mail.ru*

Наталия В. Гришина

*Российский государственный гуманитарный
университет, Москва, Россия;*

*Московский государственный лингвистический университет,
Москва, Россия, grnat@rambler.ru*

Дарья Н. Титова

*Образовательный центр «Протон», Москва, Россия,
daratitovaa@gmail.com*

Аннотация. Актуальность разработки интеллектуальных систем для организации персональных цифровых фотоархивов стремительно возрастает в условиях роста объемов визуальных данных и ужесточения требований к конфиденциальности и безопасности персональной информации. Несмотря на наличие на рынке различных решений, таких как Google Photos и Apple Photos, у них имеются фундаментальные ограничения: зависимость от интернет-соединения и отсутствие возможности сложной семантической фильтрации, в частности, поиска изображений, на которых присутствует заданная группа людей одновременно. Целью работы является обоснование методологической базы построения локальной системы, способной к автоматической детекции, идентификации и многофакторной фильтрации изображений по уникальным лицевым дескрипторам. В основе методологии системы лежит интеграция современных библиотек компьютерного зрения. Ядро распознавания построено на библиотеке face_recognition, использующей нейросетевую архитектуру ResNet для генерации 128-мерных векторных представлений лиц. Сравнение эмбедингов выполняется по метрике евклидова расстояния с адаптивным порогом схожести. Уникальной особенностью системы является

© Титов А.П., Гришина Н.В., Титова Д.Н., 2026

алгоритм контекстно-зависимой фильтрации, позволяющий находить изображения, содержащие заданную комбинацию людей. Обоснована потенциальная эффективность локальной системы, которая не только будет конкурентоспособна с облачными аналогами по точности, но способна превзойти их по критериям конфиденциальности, стоимости владения и наличию уникальной функции группового поиска.

Ключевые слова: распознавание лиц, многофакторная фильтрация изображений, цифровой фотоархив, детекция, компьютерное зрение, нейросетевая архитектура ResNet

Для цитирования: Титов А.П., Гришина Н.В., Титова Д.Н. Концепция локального органайзера фотогалереи на основе распознавания с многофакторной фильтрацией лиц // Вестник РГГУ. Серия «Информатика. Информационная безопасность. Математика». 2026. № 1. С. 71–85. DOI: 10.28995/2686-679X-2026-1-71-85

The concept of a local photo gallery organizer based on recognition with multifactorial face filtering

Andrei P. Titov

*MIREA – Russian Technological University, Moscow, Russia;
Institute of Cybersecurity and Digital Technologies, Moscow, Russia,
titov_and@mail.ru*

Natalia V. Grishina

*Russian State University for the Humanities, Moscow, Russia;
Moscow State Linguistic University, Moscow, Russia,
gnat@rambler.ru*

Darya N. Titova

*Proton Educational Center,
Moscow, Russia, titov_and@mail.ru*

Annotation. The relevance of developing intelligent systems for organizing personal digital photo archives is rapidly increasing in the context of growing volumes of visual data and stricter requirements for the confidentiality and security of personal information. Despite the availability of various solutions on the market, such as Google Photos and Apple Photos, they have fundamental limitations: dependence on an Internet connection and the lack of sophisticated semantic filtering, in particular, searching for images where a given group of people is present at the same time. The aim of the work is to substantiate the methodological basis for building a local system capable of automatic detection,

identification and multifactorial filtering of images by unique facial descriptors. The system's methodology is based on the integration of modern computer vision libraries. The recognition core is based on the face_recognition library, which uses the ResNet neural network architecture to generate 128-dimensional vector representations of faces. Embeddings are compared using the Euclidean distance metric with an adaptive similarity threshold. A unique feature of the system is the context-sensitive filtering algorithm, which allows you to find images containing a given combination of people. The potential efficiency of the on-premises system is justified, which will not only be competitive with cloud counterparts in terms of accuracy, but will also be able to surpass them in terms of privacy, cost of ownership, and the availability of a unique group search function.

Keywords: facial recognition, multifactorial image filtering, digital photo archive, detection, computer vision, ResNet neural network architecture

For citation: Titov, A.P., Grishina, N.V. and Titova, D.N. (2026), "The concept of a local photo gallery organizer based on recognition with multifactorial face filtering", *RSUH/RGGU Bulletin. "Information Science. Information Security. Mathematics" Series*, no. 1, pp. 71–85, DOI: 10.28995/2686-679X-2026-1-71-85

Введение

Развитие компьютерного зрения характеризуется быстрой эволюцией от классических алгоритмических подходов к глубоким нейронным сетям, способным решать задачи огромной сложности. За последнее десятилетие произошел качественный скачок в точности и эффективности методов распознавания образов. Это открыло возможности для практического применения компьютерного зрения в различных областях. Основу современных методов обработки изображений составляют сверточные нейронные сети (Convolutional Neural Networks, CNN), архитектура которых позволяет эффективно выявлять иерархические признаки в визуальных данных. Работы, посвященные AlexNet (2012), VGG (2014), ResNet (2015) и EfficientNet (2019), демонстрируют последовательное совершенствование как точности, так и эффективности использования вычислительных ресурсов. Особое значение имеет появление архитектур, специально оптимизированных для задач распознавания лиц – FaceNet, ArcFace, CosFace, которые используют специализированные функции потерь (triplet loss, angular margin loss) для создания высококачественных эмбеддингов лиц в метрических пространствах [Домингос 2024].

Современные системы распознавания лиц реализуют многоступенчатый pipeline, включающий детекцию лиц, их выравнивание (alignment), извлечение признаков и сравнительный анализ. Для этапа детекции доминирующими стали методы на основе CNN, такие как MTCNN (Multi-task Cascaded Convolutional Networks), обеспечивающие высокую точность даже в условиях сложного освещения, частичной окклюзии и вариативных ракурсов. В области извлечения признаков наблюдается переход от локальных дескрипторов (типа SIFT, SURF) к глубоким эмбедингам, получаемым с помощью нейронных сетей, обученных на миллионах изображений [Ryan 2023].

Следующим шагом стало развитие эффективных (lightweight) архитектур нейронных сетей MobileNet, ShuffleNet и SqueezeNet, которые сохраняют высокую точность при значительном сокращении вычислительной сложности. Это особенно актуально для задач локальной обработки изображений на устройствах с ограниченными ресурсами, где невозможно использование мощных GPU-кластеров. Параллельно с совершенствованием алгоритмов происходит критически важное развитие программных инструментов и фреймворков. Библиотеки типа OpenCV, Dlib, а также высокоуровневые обертки на подобии face_recognition, предоставляют исследователям и разработчикам доступ к современным методам компьютерного зрения без необходимости реализации сложных алгоритмов «с нуля». Интеграция этих библиотек с языками программирования общего назначения, в первую очередь Python, значительно снижает порог входа в область компьютерного зрения и ускоряет разработку прикладных решений.

Несмотря на успехи, остаются нерешенными проблемы, связанные с обработкой изображений в неконтролируемых условиях, обеспечением устойчивости к адверсальным атакам, а также вопросы эффективности и скорости работы на мобильных устройствах. Кроме того, этические аспекты применения технологий распознавания лиц и требования к защите персональных данных стимулируют развитие методов федеративного обучения и дифференциальной приватности в компьютерном зрении [Титов 2024].

Для персональных фотоархивов современные методы компьютерного зрения позволяют простейшие сортировки по дате или месту съемки, смысловые группировки на основе распознавания людей, объектов, сцен и событий. Однако практическая реализация этих возможностей в локальных приложениях, обеспечивающих конфиденциальность данных, представляет собой сложную научно-техническую задачу, требующую оптимального сочетания точности современных алгоритмов с эффективностью их работы на потребительском оборудовании.

Современные системы распознавания лиц выполняют последовательную обработку изображений в несколько этапов: обнаружение лица, извлечение признаков, векторизация и сравнение. Эти этапы являются основой для построения эффективных решений в области биометрической идентификации.

1. Обнаружение лица. На этом этапе система определяет, присутствует ли лицо на изображении и где оно расположено. Для решения этой задачи используются методы машинного обучения, такие как каскад Хаара (Haar Cascade), алгоритм гистограмм ориентированных градиентов (HOG), а также сверточные нейронные сети (например, MTCNN – Multi-task Cascaded Convolutional Networks) [Бурков 2020].

В табл. 1 приведено сравнение наиболее популярных методов обнаружения лиц, используемых на первом этапе обработки изображений в системах распознавания. Представленные данные позволяют оценить компромисс между точностью, скоростью работы и устойчивостью к искажениям изображения, что важно при выборе метода в зависимости от условий применения. Так, например, метод Haar Cascade отличается высокой скоростью, но уступает в точности и устойчивости, тогда как MTCNN демонстрирует высокую точность даже при сложных условиях съёмки, но требует больше вычислительных ресурсов. Такое сравнение позволяет обоснованно выбирать технологию под конкретные технические и эксплуатационные задачи.

Таблица 1

Сравнение методов обнаружения лица

Метод	Точность	Скорость	Устойчивость к искажениям	Применение
Haar Cascade	Низкая–средняя	Высокая	Низкая	Устройства с низкой мощностью веб-камеры
HOG	Средняя	Средняя	Средняя	Простые системы распознавания
MTCNN	Высокая	Средняя–низкая	Высокая	Мобильные и облачные приложения, нейросети

2. Извлечение признаков. Далее из области, содержащей лицо, извлекаются численные характеристики, описывающие его форму, расположение и пропорции ключевых точек (глаз, носа, рта, челюсти и другие). Используются глубокие нейронные сети типа

FaceNet, DeepFace, ArcFace, позволяющие получать стабильные и уникальные векторные представления.

3. Векторизация и сравнение. Извлеченные признаки преобразуются в вектор фиксированной длины. Затем вектор сравнивается с векторами из базы данных с помощью метрик, например, евклидова расстояния или косинусного сходства. При достаточном уровне совпадения лицо считается опознанным.

На рис. 1 иллюстрируется последовательность ключевых этапов, лежащих в основе работы системы распознавания лиц. Она демонстрирует переход от обнаружения области лица на изображении к извлечению уникальных признаков, и далее к этапу векторизации и сравнительного анализа с эталонной базой. Такая визуализация позволяет представить логическую структуру обработки, а также взаимосвязь между этапами, каждый из которых играет критически важную роль в обеспечении точности и надежности распознавания [Waskom 2021].




Рис. 1. Схема этапов работы системы распознавания лиц

Современные системы распознавания лиц используют широкий спектр методов машинного обучения, начиная от традиционных подходов и заканчивая сложными архитектурами глубоких нейронных сетей. Применение нейросетевых методов повысило точность и надежность систем.

Методы машинного обучения условно можно разделить на две категории: классические и глубинные. Классические подходы, такие как метод опорных векторов (SVM), деревья решений, метод главных компонент (PCA), использовались на начальных этапах развития компьютерного зрения. Эти методы имели ограниченную точность, особенно при изменении условий освещенности и угла поворота лица. Глубинное обучение позволяет обучать многослойные нейронные сети на огромных объемах изображений. Одной из наиболее известных моделей является FaceNet, которая использует сверточную нейронную сеть для извлечения признаков и обучается на задаче триплетной потери (triplet loss), минимизируя расстояние между изображениями одного человека и максимизируя между

изображениями разных людей. Архитектура ArcFace вводит дополнительный угловой штраф в функцию потерь, что улучшает разделимость векторов признаков в пространстве. Это особенно важно при необходимости отличать схожие лица, например, в больших базах данных [Динов 2023].

Нейросети позволяют также автоматически определять ключевые точки лица, что используется для выравнивания (alignment), а также для извлечения объединенного эмбединга лица, устойчивого к поворотам головы, эмоциям и освещенности. Приведенная в табл. 2 сравнительная характеристика нейросетевых моделей позволяет наглядно оценить различия между современными архитектурами, применяемыми для распознавания лиц. В таблице представлены ключевые параметры, такие как используемые методы обучения, особенности реализации и показатели точности на стандартном датасете LFW (Labeled Faces in the Wild). Эти данные подтверждают высокую эффективность глубинных моделей, таких как ArcFace и FaceNet, которые демонстрируют точность, превышающую 99%, и подчеркивают прогресс, достигнутый в области за счет использования специализированных функций потерь и архитектурных решений.

Таблица 2

Сравнение популярных нейросетевых моделей для распознавания лиц

Модель	Метод обучения	Особенности	Точность на LFW
FaceNet	Triplet Loss	Глобальный эмбединг лица	>99,6%
ArcFace	Angular Margin Loss	Высокая разделимость эмбедингов	>99,8%
DeepFace	Cross-Entropy	Была одной из первых	97,35%
CosFace	Cosine Margin Loss	Лучше различает схожие лица	99,7%

Современные программные решения для хранения и организации фотоматериалов активно используют технологии компьютерного зрения и машинного обучения, в частности распознавание лиц. Среди наиболее популярных сервисов Apple Photos, Google Photos, а также отечественные облачные решения, такие как Яндекс.Диск и Облако Mail.ru.

Apple Photos – встроенное приложение для управления фотографиями на устройствах компании Apple (iPhone, iPad, Mac). Программа автоматически сканирует галерею пользователя, выделяет лица на изображениях и создает коллекции по людям. Алгоритмы системы способны группировать фотографии по похожим лицам и предлагают пользователю ввести имя, чтобы ассоциировать его с конкретным человеком. Приложение поддерживает локальную обработку, что обеспечивает более высокий уровень конфиденциальности. Однако функциональность поиска ограничивается одним лицом за раз, т. е. пользователь не может отфильтровать фотографии, где присутствуют, например, и Анна, и Сергей одновременно.

Google Photos предоставляет облачный сервис. После загрузки изображений они обрабатываются на серверах Google с применением мощных нейросетевых моделей, включая архитектуры на базе TensorFlow. Сервис способен автоматически распознавать и группировать людей, выделять их по возрасту, полу и даже выражению лица. Пользователь может назначать имена, искать фотографии по лицам и даже задавать текстовые запросы. Однако, несмотря на широкий функционал, Google Photos также не предоставляет прямой возможности фильтрации изображений по нескольким лицам одновременно. Кроме того, обработка выполняется в облаке, что может вызывать опасения в отношении конфиденциальности данных.

Яндекс активно развивает собственную экосистему облачных решений. В приложении Яндекс.Диск реализованы функции автоматического распознавания лиц и сортировки изображений по людям. Аналогично вышеуказанным решениям, система предлагает объединение фотографий по лицам, однако интерфейс и глубина функционала ограничены. Возможность поиска изображений по нескольким лицам также отсутствует. Все данные обрабатываются на серверах компании, с частичным задействованием публичных API для анализа изображений.

Решения от Mail.ru Group и других сервисов, таких как Mega или Amazon Photos, предоставляют базовые возможности хранения и предпросмотра изображений. В некоторых из них распознавание лиц отсутствует вовсе, либо реализовано в зачаточном виде. Основной упор делается на синхронизацию и резервное копирование, а не на интеллектуальную сортировку и анализ содержимого фотоархивов.

Таким образом, несмотря на обширные возможности современных фотосервисов, ни один из них не предоставляет полного функционала, позволяющего пользователю выбрать нескольких

людей из базы распознанных лиц и найти изображения, где все они присутствуют одновременно. Этот пробел в функциональности является основным мотивационным фактором для создания системы, решающей данную задачу. В табл. 3 представлена сравнительная характеристика современных сервисов распознавания лиц.

Таблица 3

Сравнение популярных сервисов
по распознаванию лиц

Сервис	Распознавание лиц	Поиск по нескольким лицам	Местоположение обработки	Приватность
Apple Photos	Да	Нет	Локально	Высокая
Google Photos	Да	Нет	Облако	Средняя
Яндекс.Диск	Да	Нет	Облако	Средняя
Mail.ru Облако	Ограниченно	Нет	Облако	Средняя
Amazon Photos	Ограниченно	Нет	Облако	Средняя

Алгоритм работы программы представлен на рис. 2, отображающем последовательность основных этапов обработки изображений. На первом этапе пользователь указывает папку с фотографиями, которые подлежат анализу. Далее система последовательно обрабатывает каждое изображение: выполняется поиск лиц с использованием алгоритма детекции, и если лицо найдено, то программа извлекает его числовое векторное представление. Затем полученный вектор сравнивается с существующей базой известных лиц. В случае совпадения лицо автоматически идентифицируется, а при отсутствии совпадений пользователю предлагается ввести имя нового человека, который затем добавляется в базу. После предварительной обработки и накопления эмбеддингов всех распознанных лиц пользователь может выбрать одного или нескольких людей для выполнения поиска. Финальный этап заключается в фильтрации изображений: сохраняются только те фотографии, на которых одновременно присутствуют все выбранные лица. Такой пошаговый подход обеспечивает высокую точность, гибкость фильтрации и удобство взаимодействия с программой [Wickham 2014].



Рис. 2. Схема алгоритма работы программы

Процесс кодировки лиц начинается с детектирования facial landmarks (ключевых точек лица) на исходном изображении. Для этого применяется предобученная нейронная сеть, реализованная в библиотеке `face_recognition`. После успешного обнаружения лица функция `face_recognition.face_encodings()` преобразует найденную область в 128-мерный вектор признаков (эмбединг). Данное преобразование осуществляется с использованием глубокой сверточной нейронной сети, обученной на обширном датасете лиц, что обеспечивает высокую дискриминативность получаемых дескрипторов [Джеймс 2017].

Полученный эмбединг инкапсулирует наиболее значимые антропометрические характеристики лица, включая пропорции черт, форму подбородка, расстояние между глазами и другие уникальные параметры. Важными особенностями такого представления являются: инвариантность к изменению освещенности (в определенных пределах), устойчивость к умеренным изменениям ракурса (до 30 градусов по каждому из осей), а также относительная независимость от мимических изменений и аксессуаров (очки, головные уборы) [Hastie 2009].

Процедура сравнения эмбедингов основывается на вычислении метрики подобия между векторами. Основной используемой метрикой является евклидово расстояние, которое вычисляется по формуле [Deza 2006]:

$$d = \sqrt{\sum_{i=1}^{128} (x_i - y_i)^2},$$

где x и y – сравниваемые 128-мерные векторы, i – индекс измерения.

Пороговое значение для принятия решения о принадлежности векторов одному лицу обычно устанавливается в диапазоне $0,6 \pm 0,1$, что является результатом эмпирических исследований и обеспечивает оптимальный баланс между precision и recall. Для специфических случаев (например, при работе с изображениями низкого разрешения) может применяться косинусная мера сходства:

$$\text{similarity} = \frac{\sum_{i=1}^n (x_i \times y_i)}{\sqrt{\sum_{i=1}^n x_i^2} \times \sqrt{\sum_{i=1}^n y_i^2}},$$

где x и y – сравниваемые 128-мерные векторы, i – индекс измерения.

Данная метрика демонстрирует лучшую устойчивость к вариациям яркости и контраста изображений. В системе реализована возможность динамического выбора метрики сравнения в зависимости от качества входных данных.

Алгоритм фильтрации изображений по множественному присутствию лиц представляет собой многоэтапный процесс. Для каждого изображения в входном наборе выполняется детектирование всех присутствующих лиц с последующей их кодировкой. Полученные эмбединги сравниваются с эталонными векторами, соответствующими лицам, заданным в критериях поиска. Изображение считается релевантным только при выполнении двух условий: если все лица из поискового запроса должны быть обнаружены на изображении и для каждого из искомых лиц должно быть найдено соответствие с расстоянием, не превышающим установленный порог.

Для уменьшения количества ложных срабатываний реализован механизм перекрестной верификации, при котором потенциальные соответствия проверяются по нескольким соседним кадрам (для видео) или ракурсам (для наборов фотографий). Система допускает настройку следующих параметров фильтрации:

- жесткость порога сравнения (строгий/средний/мягкий режимы);
- минимальное качество детекции лица;
- максимально допустимое количество лиц в кадре;

– обработка частично скрытых лиц (с поддержкой маскирования невидимых областей).

Оптимизация алгоритма достигается за счет предварительной кластеризации эталонных векторов и использования приближенных методов поиска (локально-чувствительное хеширование) при работе с большими базами изображений.

Архитектура системы обеспечивает модульность, масштабируемость и простоту в использовании. Алгоритмы, реализованные на базе `face_recognition`, позволяют точно и эффективно обрабатывать большие массивы изображений, находить совпадения и автоматически пополнять базу лиц. Особое внимание уделяется фильтрации по нескольким лицам, что является ключевым конкурентным преимуществом разрабатываемого программного средства.

Функциональная составляющая системы базируется на алгоритмах биометрической идентификации, позволяющих с высокой точностью детектировать антропометрические объекты на цифровых изображениях. При этом каждый обнаруженный объект описывается уникальным цифровым дескриптором, формируемым с учетом ключевых антропометрических особенностей. Реализованный механизм верификации обеспечивает сравнение и сопоставление биометрических шаблонов с заданным уровнем достоверности, а адаптивные алгоритмы позволяют динамически обновлять эталонные образцы, учитывая возможные изменения внешности с течением времени.

Важнейшим аспектом системы является ее способность к автоматической категоризации визуального контента. На основе анализа биометрических характеристик осуществляется интеллектуальная группировка изображений по персоналиям, при этом учитываются временные метки и другие значимые параметры. Формируемая иерархическая структура хранения медиаданных дополняется автоматически генерируемыми метаданными, что существенно повышает эффективность последующего поиска и анализа материалов.

Интерактивный компонент системы предоставляет пользователю широкие возможности для управления процессом обработки данных. Реализованный визуальный интерфейс позволяет не только подтверждать результаты автоматической обработки, но и вносить необходимые коррективы. Особое внимание уделено инструментам ручной аннотации и редактирования, включая функции объединения и разделения категорий, а также механизмы массовой обработки групп изображений.

Поисковый функционал системы поддерживает составление сложных запросов на основе комбинации различных признаков. Реализованные алгоритмы визуализации позволяют анализировать

временные диаграммы встречаемости персон, изучать статистику частоты совместных появлений, а также экспортировать полученные результаты в структурированных форматах для последующего использования.

С научно-технической точки зрения система реализует гибридный подход, сочетающий детерминированные алгоритмы обработки изображений (в частности, НОГ-детекторы) со статистическими методами машинного обучения и эвристическими правилами для обработки пограничных случаев. Особенностью решения является наличие адаптивных механизмов обучения, позволяющих системе совершенствоваться при работе с новыми данными.

Практическая значимость разработанного решения проявляется в его способности на порядок сокращать временные затраты на организацию фотоархивов при одновременном снижении влияния субъективного фактора. Обеспечиваемая системой консистентность хранения биометрических данных и возможность реализации сложных сценариев поиска открывают новые перспективы в области управления визуальным контентом.

Заключение

В ходе проведенного исследования было проведен анализ и подбор методов для организации фотогалереи FaceGallery, основанной на распознавании лиц с поддержкой многофакторной фильтрации. Задачами программного решения станет автоматическая детекция, идентификация и, что наиболее важно, семантическая фильтрация изображений по комбинациям уникальных лицевых дескрипторов.

Методологической основой системы является интеграция современных библиотек компьютерного зрения, в первую очередь `face_recognition`, что позволит построить надежное ядро распознавания на базе нейросетевой архитектуры ResNet. Применение евклидовой метрики для сравнения 128-мерных эмбедингов с адаптивным порогом обеспечит оптимальный баланс между точностью и быстродействием.

Литература

Бунина 2024 – Бунина Л.В. Разработка модуля сохранения датасета для обнаружения столкновений с использованием полигональной сетки и нейронных сетей / Л.В. Бунина, А.П. Титов, М.А. Лихачев // Инженерный вестник Дона. 2024. № 8 (116). С. 178–185.

- Бурков 2020 – *Бурков А.* Краткая книга по машинному обучению. М.: ДМК Пресс, 2020. 160 с.
- Джеймс 2017 – *Джеймс Г., Виттен Д., Хастии Т., Тибширани Р.* Введение в статистическое обучение с применениями на R. М.: Мир, 2017. 450 с.
- Динов 2023 – *Динов И.Д.* Наука о данных и прогнозная аналитика: биомедицинские и медицинские приложения с использованием R. М.: Бином, 2023. 512 с.
- Домингос 2024 – *Домингос П.* Несколько полезных вещей, которые стоит знать о машинном обучении // *Communications of the ACM*. 2012. Т. 55, № 10. С. 78–87.
- Титов 2024 – *Титов А.П.* Анализ моделей адаптивных нейро-нечетких систем // *Вестник РГГУ. Серия «Информатика. Информационная безопасность. Математика»*. 2024. № 1. С. 21–35.
- Deza 2006 – *Deza M.-M.* Dictionary of Distances. New York: Elsevier Science, 2006. 412 p.
- Hastie 2009 – *Hastie T., Tibshirani R., Friedman J.* The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Luxembourg: Springer, 2009. 745 p.
- Ryan 2023 – *Ryan M., Massaron L.* Machine Learning for Tabular Data: XGBoost, Deep Learning, and AI. New York: Manning Publications, 2023. 320 p.
- Waskom 2021 – *Waskom M.* Seaborn: Statistical Data Visualization // *Journal of Open Source Software*. 2021. Т. 6, № 60. С. 3021.
- Wickham 2014 – *Wickham H.* Tidy Data // *Journal of Statistical Software*. 2014. Т. 59, № 10.

References

- Bunina, L.V, Titov, A.P. and Likhachev, M.A. (2024), “Development of a Dataset Saving Module for Collision Detection Using a Polygonal Mesh and Neural Networks”, *Engineering Bulletin of the Don*, no. 8 (116), pp. 178–185.
- Burkov, A.A. (2020), *Kratkaya kniga po mashinnomu obucheniyu* [Brief Book on Machine Learning], DMK Press, Moscow, Russia, 160 p.
- Deza M.-M. (2006), *Dictionary of Distances*, Elsevier Science, New York, USA, 412 p.
- Dinov, I.D. (2023), *Nauka o dannykh i prognoznaya analitika: biomeditsinskie i meditsinskie prilozheniya s ispol'zovaniem R* [Data Science and Predictive Analytics: Biomedical and Healthcare Applications with R], Binom, Moscow, Russia, 512 p.
- Domingos, P. (2012), “Some Useful Things to Know About Machine Learning”, *Communications of the ACM*, vol. 55, no. 10, pp. 78–87.
- Hastie, T., Tibshirani, R., and Friedman, J. (2009), *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Springer, Luxembourg, Luxembourg, 745 p.
- James, G., Witten, D., Hastie, T. and Tibshirani, R. (2017), *Vvedenie v statisticheskoe obuchenie s primeneniymi na R* [Introduction to Statistical Learning with Applications in R], Mir, Moscow, Russia, 450 p.
- Ryan M. and Massaron, L. (2023), *Machine Learning for Tabular Data: XGBoost, Deep Learning, and AI*, Manning Publications, New York, USA, 320 p.

- Titov, A.P. (2024), "Analysis of Models of Adaptive Neuro-Fuzzy Systems", *RSUH/ RGGU Bulletin. "Information Science. Information Security. Mathematics" Series*, no. 1, pp. 21–35.
- Waskom, M. (2021), "Seaborn: Statistical Data Visualization", *Journal of Open Source Software*, vol. 6, no. 60, p. 3021.
- Wickham, H. (2014), "Tidy Data", *Journal of Statistical Software*, vol. 59, no. 10.

Информация об авторах

Андрей П. Титов, кандидат технических наук, доцент, МИРЭА – Российский технологический университет, Москва, Россия; 119454, Россия, Москва, проспект Вернадского, д. 78; Институт кибербезопасности и цифровых технологий, Москва, Россия; 107076, Россия, Москва, ул. Стромынка, д. 20; titov_and@mail.ru

Наталья В. Гришина, кандидат технических наук, доцент, Российский государственный гуманитарный университет, Москва, Россия; 125047, Россия, Москва, Миусская пл., д. 6, стр. 6;

Московский государственный лингвистический университет, Москва, Россия; 119034, Россия, Москва, ул. Остоженка, д. 38 стр. 1; grnat@rambler.ru

Дарья Н. Титова, Образовательный центр «Протон», Москва, Россия; 121309, Россия, Москва, ул. Баркляя, д. 15, корп. 3; daratitovaa@gmail.com

Information about the authors

Andrei P. Titov, Cand. of Sci. (Computer Science), associate professor, MIREA – Russian Technological University, Moscow, Russia; bld. 78, Vernadskii Lane, Moscow, 119454, Russia;

Institute of Cybersecurity and Digital Technologies, Moscow, Russia; bld. 20, Stromynka Str., Moscow, 107076, Russia; titov_and@mail.ru

Natalia V. Grishina, Cand. of Sci. (Computer Science), associate professor, Russian State University for the Humanities, Moscow, Russia; 6-6, Miusskaya Sq., Moscow, 125047, Russia; Moscow State Linguistic University, Moscow, Russia; bldg. 1, bld. 38, Ostozhenka St., Moscow, 119034, Russia; grnat@rambler.ru

Darya N. Titova, Proton Educational Center, Moscow, Russia; bldg. 3, bld. 15, Barklaya St., Moscow, 121309, Russia; daratitovaa@gmail.com

Научный журнал
Вестник РГГУ
Серия «Информатика.
Информационная безопасность. Математика»
№ 1
2026

Дизайн обложки
Е.В. Амосова

Корректор
Ж.П. Григорьева

Компьютерная верстка
Н.В. Москвина

Учредитель и издатель
Российский государственный гуманитарный университет
125047, г. Москва, вн. тер. г. муниципальный округ Тверской,
Миусская пл., д. 6, стр. 6

Свидетельство о регистрации СМИ
ПИ № ФС77-72977 от 25.05.2018 г.
Периодическое печатное издание

Подписано в печать 07.04.2026

Выход в свет 14.04.2026

Формат 60 × 90 ¹/₁₆

Уч.-изд. л. 5,0. Усл. печ. л. 5,4

Тираж 1050 экз. Свободная цена

Заказ № 2341

Отпечатано в типографии Издательского центра
Российского государственного гуманитарного университета
125047, Москва, Миусская пл., д. 6, стр. 6
www.rsuh.ru