

ISSN 1816-0301 (Print)

ISSN 2617-6963 (Online)

ИНФОРМАТИКА

INFORMATICS

TOM 22
VOL.

3 | 2025

ОТ РЕДАКЦИИ

В журнале «Информатика» публикуются оригинальные и обзорные статьи, описывающие результаты фундаментальных и прикладных исследований специалистов академического и вузовского профиля в области информатики и информационных технологий.

Основной целью журнала является публикация наиболее значимых новых результатов в указанной области. Приветствуются статьи, описывающие заключительные результаты научных проектов и докторских исследований, открывающие новые направления исследований, которые находятся на стыке информатики и других наук.

Журнал рассчитан на широкий круг специалистов в области информатики и информационных технологий.

Основные разделы журнала:

- биоинформатика;
- математическое моделирование;
- защита информации и надежность систем;
- информационные технологии;
- логическое проектирование;
- обработка сигналов, изображений, речи, текста и распознавание образов;
- автоматизация проектирования;
- интеллектуальные системы.

Префикс DOI: 10.37661

Условия распространения материалов:

контент доступен под лицензией Creative Commons Attribution 4.0 License

Индексирование:

Высшей аттестационной комиссией Республики Беларусь журнал «Информатика» был включен в список научных изданий для опубликования результатов докторских исследований.

В декабре 2017 г. включен в базу данных Российского индекса научного цитирования (РИНЦ). С помощью инструментов и сервисов, доступных на платформе eLIBRARY (раздел «Личный кабинет»), можно самостоятельно корректировать список своих публикаций и цитирований в РИНЦ.

В июле 2017 г. включен в базу журналов открытого доступа Directory of Open Access Journals (DOAJ).

С помощью поисковых систем Google Scholar, WorldCat, Соционет можно получить свободный доступ к полному тексту научных публикаций журнала.

Адрес редакции:

ул. Сурганова, 6, к. 305, г. Минск, 220012, Беларусь

Тел. +375 (017) 351 26 22

Editorial address:

Surganova str., 6, of. 305, Minsk, 220012, Belarus

Phone +375 (017) 351 26 22

E-mail: rio@newman.bas-net.by

<https://inf.grid.by/jour>

THE EDITOR'S NOTE

The journal "Informatics" is a scientific publication in computer sciences and information technologies which reviews the results in basic and applied research of scientists from the universities and scientific centers.

The journal focuses on the most significant and modern papers of research projects results and PhD/DSc thesis in computer sciences.

The journal is edited for the specialists in IT and computer sciences research and application.

The main sections of the journal:

- bioinformatics;
- mathematical modeling;
- information protection and system reliability;
- information technology;
- logical design;
- signal, image, speech, text processing and pattern recognition;
- computer-aided design;
- artificial intelligence methods.

DOI Prefix: 10.37661

Distribution:

content is distributed under Creative Commons Attribution 4.0 License

Indexation:

the journal "Informatics" is in the list of scientific publications recommended by the Higher Attestation Commission of the Republic of Belarus for scientists to publish the results of PhD/DSc research.

In December 2017 the journal was included in the database of the Russian Science Citation Index (RISC) and provides free access to reviewed electronic scientific paper, improving scientific information traffic and also raising quotation of works of the authors (please use <https://elibrary.ru> or section for authors https://elibrary.ru_author_tools).

In July 2017 included in the database of open access journals Directory of Open Access Journals (DOAJ).

Using the Google Scholar, WorldCat, Соционет search engine, you can get free access to full text of scientific publications of magazine.

ISSN 1816-0301 (Print)
ISSN 2617-6963 (Online)

ОБЪЕДИНЕНИЙ ИНСТИТУТ ПРОБЛЕМ ИНФОРМАТИКИ
НАЦИОНАЛЬНОЙ АКАДЕМИИ НАУК БЕЛАРУСИ

ИНФОРМАТИКА

Informatika

Том 22, № 3, июль-сентябрь 2025

Ежеквартальный научный журнал

Издаётся с января 2004 г.

Учредитель и издатель – государственное научное учреждение «Объединенный институт проблем информатики Национальной академии наук Беларусь» (ОИПИ НАН Беларусь)

Главный редактор

Кругликов Сергей Владимирович, д-р воен. наук, канд. техн. наук, доцент,
ОИПИ НАН Беларусь (Минск, Беларусь)

Заместитель главного редактора

Тузиков Александр Васильевич, д-р физ.-мат. наук, проф., чл.-корр. НАН Беларусь,
ОИПИ НАН Беларусь (Минск, Беларусь)

Редакционная коллегия

Абламейко Сергей Владимирович, д-р техн. наук, проф., академик НАН Беларусь, БГУ (Минск, Беларусь)

Анищенко Владимир Викторович, канд. техн. наук, доцент, ООО «СофтКлуб» (Минск, Беларусь)

Бибило Петр Николаевич, д-р техн. наук, проф., ОИПИ НАН Беларусь (Минск, Беларусь)

Бобов Михаил Никитич, д-р техн. наук, проф., БГУИР (Минск, Беларусь)

Долгий Александр Борисович, д-р техн. наук, проф., Высшая инженерная школа Бретани (Нант, Франция)

Дудин Александр Николаевич, д-р физ.-мат. наук, проф., БГУ (Минск, Беларусь)

Карпов Алексей Анатольевич, д-р техн. наук, доцент, СПИИРАН (Санкт-Петербург, Россия)

Ковалев Михаил Яковлевич, д-р физ.-мат. наук, проф., чл.-корр. НАН Беларусь, ОИПИ НАН Беларусь
(Минск, Беларусь)

Килин Сергей Яковлевич, д-р физ.-мат. наук, проф., академик НАН Беларусь, Центр «Квантовая оптика и квантовая информатика» Института физики им. Б. И. Степанова НАН Беларусь (Минск, Беларусь)

Краснопрошин Виктор Владимирович, д-р техн. наук, проф., БГУ (Минск, Беларусь)

Крот Александр Михайлович, д-р техн. наук, проф., ОИПИ НАН Беларусь (Минск, Беларусь)

Лиходед Николай Александрович, д-р физ.-мат. наук, проф., БГУ (Минск, Беларусь)

Матус Петр Павлович, д-р физ.-мат. наук, проф., Институт математики НАН Беларусь (Минск, Беларусь)

Скляров Валерий Анатольевич, д-р техн. наук, проф., Университет Авейру (Авейру, Португалия)

Сотков Юрий Назарович, д-р физ.-мат. наук, проф., ОИПИ НАН Беларусь (Минск, Беларусь)

Харин Юрий Семенович, д-р физ.-мат. наук, проф., академик НАН Беларусь, НИИ ППМИ БГУ
(Минск, Беларусь)

Черемисинова Людмила Дмитриевна, д-р техн. наук, проф., ОИПИ НАН Беларусь (Минск, Беларусь)

Чернявский Александр Федорович, д-р техн. наук, проф., академик НАН Беларусь, НИИ ПФП
им. А. Н. Севченко БГУ (Минск, Беларусь)

Ярмолик Вячеслав Николаевич, д-р техн. наук, проф., БГУИР (Минск, Беларусь)

Редакционный совет

Ефанов Дмитрий Викторович, Российский университет транспорта (Московский институт инженеров транспорта) (Москва, Россия)

Кумари Мадху, Университетский центр исследований и разработок, Университет Чандигарха (Мохали, Пенджаб, Индия)

Лазарев Александр Алексеевич, Институт проблем управления им. В. А. Трапезникова РАН (Москва, Россия)

Лай Цунг-Чьян, Азиатский университет в Тайчжуне (Китайская Народная Республика, Тайвань)

Марина Нинослав, Университет информационных наук и технологий им. Св. апостола Павла (Охрид, Македония)

Меликян Вазген Шаваршович, Национальный политехнический университет Армении (Ереван, Армения)

Пеш Эрвин, Зигенский университет (Зиген, Германия)

Сингх Таджиндер, Институт инженерии и технологий Сант Лонговал (Лонговал, Пенджаб, Индия)

Ходаченко Максим Леонидович, Институт космических исследований Австрийской академии наук (Грац, Австрия)

Чиулла Карло, Университет Эпока (Тирана, Албания)

Штейнберг Борис Яковлевич, Институт математики, механики и компьютерных наук Южного федерального университета (Ростов-на-Дону, Россия)

ИНФОРМАТИКА

Том 22, № 3, июль-сентябрь 2025

Ответственный за выпуск *Мойсейчик Светлана Сергеевна*

Редактор *Гончаренко Галина Борисовна*

Компьютерная верстка *Бутевич Ольга Борисовна*

Сдано в набор 29.08.2025. Подписано в печать 22.09.2025. Формат 60×84 1/8. Бумага офсетная.
Гарнитура Таймс. Ризография. Усл. печ. л. 11,4. Уч.-изд. л. 11,2. Тираж 40 экз. Заказ 6.

Государственное научное учреждение «Объединенный институт проблем информатики
Национальной академии наук Беларусь».

Свидетельство о государственной регистрации издателя, изготовителя, распространителя печатных изданий
№ 1/274 от 04.04.2014. ЛП № 38200000016516 от 18.12.13. Ул. Сурганова, 6, 220012, Минск, Беларусь.

ISSN 1816-0301 (Print)
ISSN 2617-6963 (Online)

THE UNITED INSTITUTE OF INFORMATICS PROBLEMS
OF THE NATIONAL ACADEMY OF SCIENCES OF BELARUS

INFORMATICS

Vol. 22, no. 3, July-September 2025

Published quarterly

Issued since January 2004

Founder and publisher – State Scientific Institution "The United Institute of Informatics Problems of the National Academy of Sciences of Belarus" (UIIP NASB)

Editor-in-Chief

Sergey V. Kruglikov, D. Sc. (Milit.), Ph. D. (Eng.), Assoc. Prof., UIIP NASB (Minsk, Belarus)

Deputy Editor-in-Chief

Alexander V. Tuzikov, D. Sc. (Phys.-Math.), Prof., Corr. Member of NASB,
UIIP NASB (Minsk, Belarus)

Editorial Board

Sergey V. Ablameyko, D. Sc. (Eng.), Prof., Academician of NASB, BSU (Minsk, Belarus)

Uladimir V. Anishchanka, Ph. D. (Eng.), Assoc. Prof., SoftClub Ltd. (Minsk, Belarus)

Petr N. Bibilo, D. Sc. (Eng.), Prof., UIIP NASB (Minsk, Belarus)

Mikhail N. Bobov, D. Sc. (Eng.), Prof., BSUIR (Minsk, Belarus)

Alexandre B. Dolgui, D. Sc. (Eng.), Prof., IMT Atlantique (Nantes, France)

Alexander N. Dudin, D. Sc. (Phys.-Math.), Prof., BSU (Minsk, Belarus)

Alexey A. Karpov, D. Sc. (Eng.), Assoc. Prof., SPII RAS (Saint Petersburg, Russia)

Mikhail Y. Kovalyov, D. Sc. (Phys.-Math.), Prof., Corr. Member of NASB, UIIP NASB (Minsk, Belarus)

Sergey Ya. Kilin, D. Sc. (Phys.-Math.), Prof., Academician of NASB, Center of Quantum Optics and Quantum Information of B. I. Stepanov Institute of Physics NASB (Minsk, Belarus)

Viktor V. Krasnoproschin, D. Sc. (Eng.), Prof., BSU (Minsk, Belarus)

Alexander M. Krot, D. Sc. (Eng.), Prof., UIIP NASB (Minsk, Belarus)

Nikolai A. Likhoded, D. Sc. (Phys.-Math.), Prof., BSU (Minsk, Belarus)

Petr P. Matus, D. Sc. (Phys.-Math.), Prof., Institute of Mathematics of NASB (Minsk, Belarus)

Valery A. Sklyarov, D. Sc. (Eng.), Prof., University of Aveiro (Aveiro, Portugal)

Yuri N. Sotskov, D. Sc. (Phys.-Math.), Prof., UIIP NASB (Minsk, Belarus)

Yuriy S. Kharin, D. Sc. (Phys.-Math.), Prof., Academician of NASB, RI APMI BSU (Minsk, Belarus)

Ljudmila D. Cheremisinova, D. Sc. (Eng.), Prof., UIIP NASB (Minsk, Belarus)

Alexander F. Cherniavsky, D. Sc. (Eng.), Prof., Academician of NASB, A. N. Sevchenko IAPP BSU (Minsk, Belarus)

Vyacheslav N. Yarmolik, D. Sc. (Eng.), Prof., BSUIR (Minsk, Belarus)

Editorial Council

- Dmitry V. Efanov**, Russian University of Transport (Moscow Institute of Transport Engineers) (Moscow, Russia)
Madhu Kumari, University Center for Research & Development, Chandigarh University (Mohali, Punjab, India)
Alexander A. Lazarev, V. A. Trapeznikov Institute of Control Sciences of the RAS (Moscow, Russia)
Tsung-Chyan Lai, Asia University at Taichung (The People's Republic of China, Taiwan)
Ninoslav Marina, St. Paul the Apostle University of Information Sciences and Technology (Ohrid, Macedonia)
Vazgen Sh. Melikyan, National Polytechnic University of Armenia (Yerevan, Armenia)
Erwin Pesch, University of Siegen (Siegen, Germany)
Tajinder Singh, Sant Longowal Institute of Engineering & Technology (Longowal, Punjab, India)
Maxim L. Khodachenko, Space Research Institute, Austrian Academy of Sciences (Graz, Austria)
Carlo Ciulla, Epoka University (Tirana, Albania)
Boris Steinberg, Institute of Mathematics, Mechanics and Computer Science Southern Federal University (Rostov-on-Don, Russia)

INFORMATICS

Vol. 22, no. 3, July-September 2025

Issue Head *Sviatlana S. Maiseichyk*

Editor *Halina B. Hancharenka*

Computer Imposition *Volha B. Butsevich*

Sent for press 29.08.2025. Output 22.09.2025. Format 60×84 1/8. Offset paper. Headset Times. Riesography.
Printed sheets 11,4. Publisher's signatures 11,2. Circulation 40 copies. Order 6.

State Scientific Institution "The United Institute of Informatics Problems of the National Academy
of Sciences of Belarus".

Certificate on the state registration of the publisher, manufacturer, distributor of printing editions
no. 1/274 dated 04.04.2014. License for the press no. 38200000016516 dated 18.12.13.
6, Surganova Str., 220012, Minsk, Belarus.

ISSN 1816-0301 (Print)
ISSN 2617-6963 (Online)

СОДЕРЖАНИЕ

ОБРАБОТКА СИГНАЛОВ, ИЗОБРАЖЕНИЙ, РЕЧИ, ТЕКСТА И РАСПОЗНАВАНИЕ ОБРАЗОВ

- Paulenka D. A., Kosareva A. A., Snezhko E. V., Kovalev V. A.** Algorithm for lung pathology detection in X-ray images using binary classification with emphasis on preprocessing..... 7

- Кузьменков Л. П., Чуйко В. А., Козлова Е. И.** Система транскрибации речи и перевода с русского языка на китайский 25

- Котова К. А., Садов В. С.** Извлечение и анализ микровыражений в задаче нейросетевого распознавания лжи по видеоизображению лица 35

БИОИНФОРМАТИКА

- Красько О. В., Якубовский С. В., Кипень В. Н.** Алгоритм выбора референсных миРНК при классификации биологических процессов 45

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ

- Шушкевич Г. Ч.** Аналитическое решение задачи экранирования низкочастотного магнитного поля тонкими сферическими экранами 59

ЗАЩИТА ИНФОРМАЦИИ И НАДЕЖНОСТЬ СИСТЕМ

- Латушкин К. В., Харин Ю. С.** Аппроксимация двоичных функций на основе двухслойной искусственной нейронной сети..... 72

- Петров С. Н., Мяделец А. О., Кундас Е. В.** Программный модуль для детектирования мошеннических веб-сайтов с использованием классификации на основе методов машинного обучения 83

УЧЕНЫЕ БЕЛАРУСИ

- Старовойтов Валерий Васильевич (к 70-летию со дня рождения)** 95

ИНФОРМАЦИЯ

- Кругликов С. В., Касанин С. Н., Абламейко М. С., Михалева Т. Н., Минько Н. С.** О правовом регулировании использования и развития технологий искусственного интеллекта 99

ISSN 1816-0301 (Print)
ISSN 2617-6963 (Online)

CONTENTS

SIGNAL, IMAGE, SPEECH, TEXT PROCESSING AND PATTERN RECOGNITION

- Paulenka D. A., Kosareva A. A., Snejhko E. V., Kovalev V. A.** Algorithm for lung pathology detection in X-ray images using binary classification with emphasis on preprocessing..... 7

- Kuzmenkov L. P., Chuyko V. A., Kazlova A. I.** Speech transcription and translation system from Russian to Chinese 25

- Kotova K. A., Sadov V. S.** Extracting and analysing micro-expressions in a neural network lie detection task 35

BIOINFORMATICS

- Krasko O. V., Yakubouski S. U., Kipen V. N.** Algorithm for selecting reference microRNAs in biological processes classification 45

MATHEMATICAL MODELING

- Shushkevich G. Ch.** Analytical solution of the shielding low-frequency magnetic field by thin spherical screens problem 59

INFORMATION PROTECTION AND SYSTEM RELIABILITY

- Latushkin K. V., Kharin Yu. S.** Approximation of binary functions based on two-layer artificial neural network..... 72

- Petrov S. N., Myadelets A. O., Kundas E. V.** Software module for detecting fraudulent websites using classification based on machine learning methods 83

SCIENTISTS OF BELARUS

- Starovoitov Valery Vasilyevich (on the 70th anniversary of his birth)** 95

INFORMATION

- Kruglikov S. V., Kasanin S. N., Ablameyko M. S., Mikhaleva T. N., Minko N. S.**
On legal regulation of the use and development of artificial intelligence technologies 99

ОБРАБОТКА СИГНАЛОВ, ИЗОБРАЖЕНИЙ, РЕЧИ, ТЕКСТА И РАСПОЗНАВАНИЕ ОБРАЗОВ

SIGNAL, IMAGE, SPEECH, TEXT PROCESSING AND PATTERN RECOGNITION



UDC 004.93'1; 004.932
DOI: 10.37661/1816-0301-2025-22-3-7-24

Original Article
Оригинальная статья

Algorithm for lung pathology detection in X-ray images using binary classification with emphasis on preprocessing

Dzmitry A. Paulenka[✉], Aleksandra A. Kosareva, Eduard V. Snezhko, Vassili A. Kovalev

The United Institute of Informatics Problems
of the National Academy of Sciences of Belarus,
st. Surganova, 6, Minsk, 220012, Belarus
[✉]E-mail: dmitri.pavlenko@gmail.com

Abstract

Objectives. The purpose of the work is automatic detection of lung lesions: cavities, infiltrates, and nodules on chest X-ray images. Also, the possibility of spatial localization of these lesions on the image is investigated.

Methods. Binary classification using deep convolutional neural networks and the Grad-CAM method are used.

Results. For the Xception model, the binary classification accuracy on the test dataset is 73.1% for cavities, 71.9% for infiltrates, and 72.8% for nodules. Heat maps with true positive outcomes for cavities and nodules are mostly understandable to radiologists. More research is needed to get heat maps for infiltrates that are understandable to experts.

Conclusion. The average classification accuracy of the Xception model for three lesion types (cavities, infiltrates, and nodules) is equal to 72.6%. Heat maps associated with pathological processes in the lungs and lesion localization were constructed. Obtained results are good, but not excellent. Thus, further investigation should be done to improve the classification accuracy and quality of the heat maps.

Keywords: medical image processing, image analysis, lung lesions, deep learning, binary classification, computer-aided diagnosis, chest X-ray, Grad-CAM

Acknowledgements. The work was carried out with the financial support of the ISTC-PR150 "Belarus TB Database and TB Portal" project and BRFFR project No. Ф22КИТГ-001 "Targeted cyclic peptide-mediated calcification therapy and early imaging diagnosis of lung cancer". The work was carried out with the funding of the State Program of Scientific Research "Digital and Space Technologies, Human, Society and State Security 2021-2025", subprogram "Digital Technologies and Space Informatics", task 1.1.3. Special thanks to the radiologist expert Oleg V. Tarasov for his valuable expertise during the research. Special gratitude to Mr. Andrei Gabrielian for the helpful questions and feedback.

For citation. Paulenka D. A., Kosareva A. A., Snezhko E. V., Kovalev V. A. *Algorithm for lung pathology detection in X-ray images using binary classification with emphasis on preprocessing*. Informatika [Informatics], 2025, vol. 22, no. 3, pp. 7–24. DOI: 10.37661/1816-0301-2025-22-3-7-24.

Conflict of interest. The authors declare of no conflict of interest.

Алгоритм обнаружения патологии легких на рентгеновских снимках с использованием бинарной классификации с акцентом на предварительную обработку

Д. А. Павленко[✉], А. А. Косарева, Э. В. Снежко, В. А. Ковалев

Объединенный институт проблем информатики

*Национальной академии наук Беларусь,
ул. Сурганова, 6, Минск, 220012, Беларусь*

[✉]E-mail: dmitri.pavlenko@gmail.com

Аннотация

Цели. Осуществляется автоматическое обнаружение поражений легких: полостей, инфильтратов и узелков – на рентгеновских снимках грудной клетки. Также исследуется возможность пространственной локализации этих поражений на изображении.

Методы. Используются бинарная классификация при помощи глубоких сверточных нейронных сетей и метод Grad-CAM.

Результаты. Для модели Xception точность бинарной классификации на тестовом наборе данных составляет: 73,1 % для полостей, 71,9 % для инфильтратов и 72,8 % для узелков. Тепловые карты с истинно положительными результатами для полостей и узелков в основном понятны радиологам. Чтобы получить понятные экспертам тепловые карты для инфильтратов, необходимо провести дополнительные исследования.

Заключение. Средняя точность классификации модели Xception для трех типов поражений (полости, инфильтраты и узелки) равна 72,6 %. Были построены тепловые карты, связанные с патологическими процессами в легких и локализацией поражений. Полученные результаты являются хорошими, но не отличными. Таким образом, необходимо провести дальнейшие исследования для повышения точности классификации и качества тепловых карт.

Ключевые слова: обработка медицинских изображений, анализ изображений, поражения легких, глубокое обучение, бинарная классификация, автоматизированная диагностика, рентгенография грудной клетки, метод Grad-CAM

Благодарности. Работа выполнена при финансовой поддержке: проекта ISTC-PR150 «Белорусская база данных по туберкулезу и туберкулезный портал»; проекта БРФФИ № Ф22КИТГ-001 «Целевая терапия кальцификации, опосредованной циклическими пептидами, и ранняя визуализирующая диагностика рака легких»; ГПНИ «Цифровые и космические технологии, безопасность человека, общества и государства 2021–2025», подпрограмма «Цифровые технологии и космическая информатика», задание 1.1.3. Особая благодарность выражается врачу-рентгенологу Олегу Владимировичу Тарасову за ценную экспертизу во время проведения исследований, а также Андрею Габриэлюну за полезные вопросы и отзывы.

Для цитирования. Алгоритм обнаружения патологии легких на рентгеновских снимках с использованием бинарной классификации с акцентом на предварительную обработку / Д. А. Павленко, А. А. Косарева, Э. В. Снежко, В. А. Ковалев // Информатика. – 2025. – Т. 22, № 3. – С. 7–24. – DOI: 10.37661/1816-0301-2025-22-3-7-24.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Introduction. In recent years, artificial intelligence-based clinical decision support systems (AI-CDSS) have gained substantial traction in the medical domain, driven by advancements in deep learning and the increasing availability of annotated medical imaging datasets. These systems are increasingly recognized for their potential to enhance diagnostic precision, reduce inter-observer variability, and streamline clinical workflows. Among various applications, AI-driven solutions for radiological image analysis have emerged as a particularly active area of research and development. Modern convolutional neural networks and vision transformers are being widely employed to perform

tasks such as lesion detection, segmentation, and classification across modalities including computed tomography (CT), magnetic resonance imaging (MRI), and X-ray. Such tools are especially valuable in scenarios requiring rapid and reliable interpretation of complex images, where human expertise may be limited or subject to fatigue-induced errors. Despite promising results, challenges remain regarding model generalizability, interpretability, and integration into clinical practice.

Addressing the challenges of tuberculosis diagnosis is crucial due to its significant impact on public health and the need for timely, reliable interventions. Several approaches have been proposed in the literature for the AI-CDSS aimed at tuberculosis diagnostics.

One of the key challenges in developing systems for delineating pathological areas is the need for labor-intensive manual segmentation, which places a substantial burden on radiologists and hinders the efficient annotation of large-scale medical imaging datasets. There is a clear need for the development of methods capable of identifying pathological regions in the absence of segmentation annotations.

The investigation goal is *to automatically detect lesions and construct heat maps associated with pathological processes in the lungs*. To achieve the goal we trained convolutional neural networks for the automatic detection of lung lesions: *cavities, infiltrates, and nodules*. Also, we investigated the possibility of spatial localization of these lesions in the chest X-ray (CXR) image. In the paper, we'll describe in detail the dataset preparation, training process, and the results obtained. The main concept is illustrated in fig. 1.

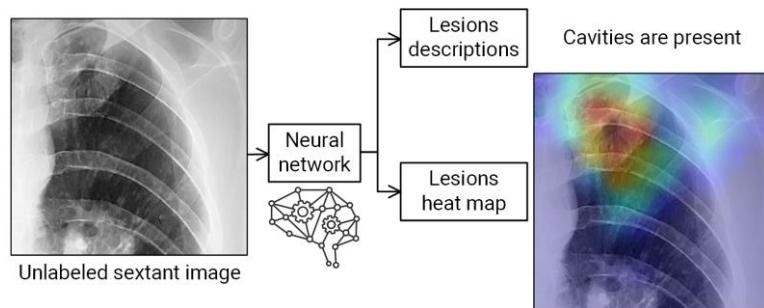


Fig. 1. Scheme of AI-CDSS to help a specialist

As shown in fig. 1, an unlabeled lobe (lung sextant) of the CXR image is input to the experimental software. The experimental AI-CDSS results in lesion descriptions and corresponding heat maps with spatial localization of these lesions.

An overview of existing solutions was conducted to identify relevant methodologies and approaches. In paper [1], the authors present a detailed literature review of existing solutions for detecting tuberculosis on chest X-rays. Existing publications present several conceptually similar approaches to the problem under consideration [2–4]. The authors [2] achieved a high classification accuracy of 96% in distinguishing tuberculosis from non-tuberculosis cases. However, their study exhibits several notable differences. First, the authors utilized images characterized by high contrast. Second, their approach did not include differential diagnosis of pathologies – specifically, the classification of lesion types. Activation maps have been derived during the training of CNN-based classifiers [3]. The authors developed an ensemble of neural networks for the classification of tuberculosis, achieving an overall accuracy of 82.93%. Notably, the model demonstrated higher performance – reaching 90% accuracy – in identifying specific pathological patterns such as effusion, infiltration, mass, and nodule (when dividing the data set into training and test samples in a ratio of 8:2). However, the accuracy was lower for other pathologies, such as fibrosis. A distinctive feature of our work is the classification of sextants, which was employed to enhance the accuracy of pathological area localization in the generation of activation maps.

We used image analysis of lung lobes (sextants) cropped by the lung mask rather than the whole CXR image. Image analysis of whole CXR images (cropped by the lung mask too) gave lower accuracy. Before being sent to the neural network the image is compressed to 299×299 or

224×224 pixels. This image compression makes small lesion foci invisible or faintly visible. Thus, processing lung lobes (sextants) instead of the whole lung preserves small lesion foci for processing by the neural network.

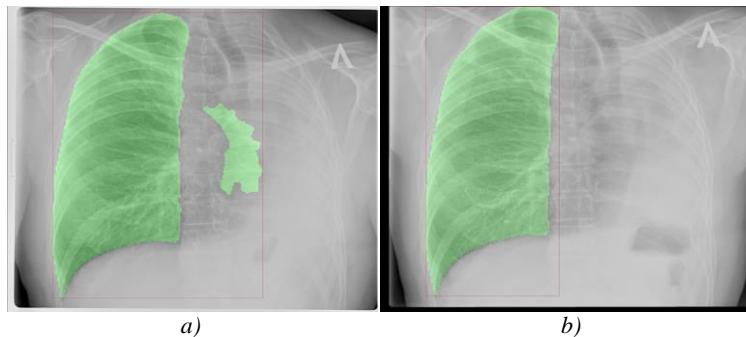


Fig. 2. Example images with a missing lung:
a) image with an incorrectly generated one lung mask;
b) image (patient ID 248) with a correctly generated one lung mask

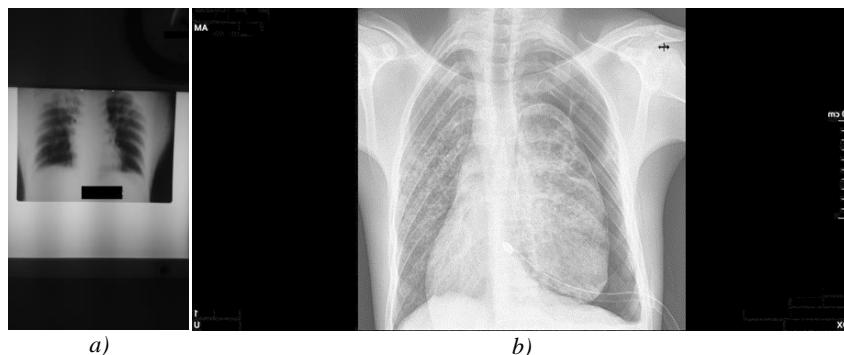


Fig. 3. Example images for which no masks were generated:
a) poor quality image (patient ID 2841);
b) an image with too large black background area (patient ID 16325)

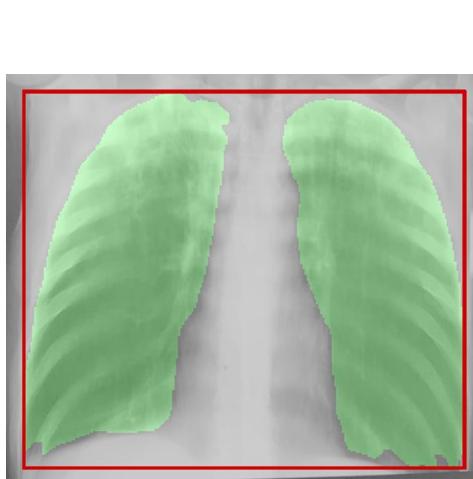


Fig. 4. Example of generated image for manual mask review

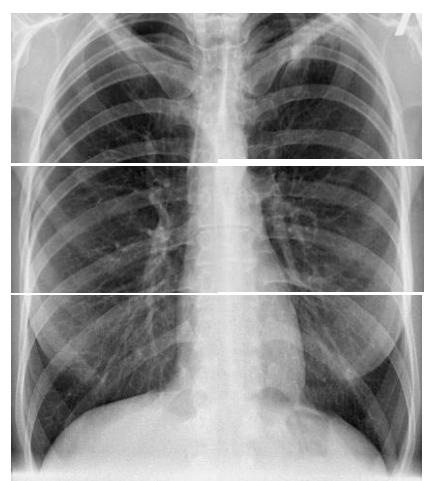


Fig. 5. Example of dividing lungs into six parts (sextants) by mask area

Experimental AI-CDSS to assist radiologists is based on a neural network and artificial intelligence techniques. The output of experimental software is lesion descriptions (for example, "cavities are present") and lesions heat map that highlights these lesions on CXR. AI-CDSS automatically produces results for three lesion types: cavities, infiltrates, and nodules.

To get lesion descriptors we used a binary classification method. Binary classification [1] is classifying the elements of a set into one of two groups (each called a class). For example, to determine if CXR has cavities or not.

To get heat maps we used the Gradient-weighted Class Activation Mapping (Grad-CAM) method [5]. Grad-CAM uses the gradients, flowing into the final convolutional layer to produce a coarse localization map highlighting important regions in the image for predicting the classes. That is, the Grad-CAM method allows one to visualize the areas of high attention of the neural network, based on which it makes the final decision.

To retrieve a dataset of sextants from the original CXR database of the TB Portals Case Browser [6] (URL: <https://data.tbportals.niaid.nih.gov>) and TB DEPOT [7] (Data Exploration Portal, URL: <https://depot.tbportals.niaid.nih.gov>) a lot of preliminary work that has to be completed:

1. manually exclude inappropriate images with lateral patient orientation, containing large white/black frames, with incorrect modality, containing other body parts, etc.;
2. automatically invert the image in color if it is inverted;
3. automatically flip the image if it is flipped horizontally (the heart is on the right side);
4. develop an algorithm for automatically cutting lungs into sextants;
5. conduct a quantitative analysis of the obtained data.

Steps 1–3 were described in the research paper [8]. Steps 4 and 5 are explained in this paper.

Algorithm for cutting lung into sextants. To work with lung sextants, it is necessary to correctly automatically slice lung images into parts. During a meeting with the radiologist, it was determined that the sextant separation when annotating images is interrelated with anatomical aspects of the position of veins, arteries, etc. In more detail, the division of the lung into lobes is made by a radiologist according to the following rules.

For CXR scans:

- upper sextants are above the lower edge of the aortic arch;
- middle sextants are between the lower edge of the aortic arch and the right inferior pulmonary vein;
- lower sextants are below the right inferior pulmonary vein.

For CT scans:

- upper sextants are above keel level;
- middle sextants are between the keel and right inferior pulmonary vein;
- lower sextants are below the right inferior pulmonary vein.

In this formulation, dividing the lungs into lobes based on anatomical image maps is a challenging task in itself, as it cannot be adequately captured by a simple mathematical algorithm due to its reliance on complex anatomical structures. In addition, there is always the possibility of human error in annotation, since some lesions in the lungs are on the border of the sextants selected by the radiologist.

According to the CXR images processing pipeline proposed in the article [8], lung masks were obtained automatically using the application program interface (API) of the *LungExpert* [9, 10]. This software is available online for testing at URL: <https://lungs.org.by>.

When cropping the lungs according to their automatically generated mask, several difficulties arose. The lung mask is incorrectly positioned under the following conditions:

- lung collapse is present (fig. 2, a);
- poor quality of the original image (fig. 3, a);
- too large black background on the image (fig. 3, b);
- presence of foreign objects on the image.

To identify images with incorrectly generated lung masks, they were viewed in two ways: automatically, using algorithmic processing of lung mask regions, and by manual review. This semi-automatic approach allowed minimizing the number of incorrectly generated masks.

For manual review of the images, previews were created that included a lung mask overlaid on the CXR and a rectangular cropping frame where the image should be cropped (fig. 4).

To organize semi-automatic search and correction of images with *incorrectly generated masks*, the ratio of two lung mask areas was used. To calculate the ratio of two lung mask areas, the number of lung mask contours is counted. Ideally, there should be two contours for the left and right lung. The first two contours with the largest areas S_1 and S_2 are then found. If there are third, fourth, etc. contours, *they are ignored*. The ratio of lung areas S_2/S_1 is in the range $[0, 1]$, where S_1 is the area of the largest contour and S_2 is the area of the second largest contour.

To determine the S_2/S_1 ratio value for the correctly generated mask, this ratio was calculated for each of the images in the original dataset. A total of 10,475 masks and corresponding ratios were obtained (tabl. 1).

Table 1
Number of images with lung area ratio in the intervals

Column No.	1	2	3	4	5	6	7	8	9	10	11
Lung area ratio interval	0.0	(0.0, 0.1]	(0.1, 0.2]	(0.2, 0.3]	(0.3, 0.4]	(0.4, 0.5]	(0.5, 0.6]	(0.6, 0.7]	(0.7, 0.8]	(0.8, 0.9]	(0.9, 1.0]
Number of images	514	35	54	132	179	363	671	1,378	2,519	3,223	1,407

Of this tabl. 1, 514 images of column 1 had only one lung mask contour ($S_2/S_1=0$). Single-lung masks were considered "correct" and processed according to a separate procedure described below.

The images with different ratios were then partially manually reviewed. After manual review, a ratio of 0.6 was *experimentally* chosen as the boundary for "correct" and "incorrect" lung masks.

If the ratio is strictly greater than 0.6 ($S_2/S_1>0.6$), we consider the mask to be "correct" (see columns 8–11 in tabl. 1). In total, 230 images from columns 8–11 were manually reviewed and subsequently excluded from the final dataset due to errors in lung mask definition.

If the ratio is less than or equal to 0.6 ($S_2/S_1\leq 0.6$) and not equal to zero ($S_2/S_1\neq 0$), we consider the mask to be "incorrect" (see columns 2–7 in tabl. 1). We excluded the "incorrect" masks from further study and did not cut them into sextants. This is a simplified approach that could probably be improved.

Before cropping the 'correct' masks, a padding of 3% is added to both the width and height of the bounding frame, but not exceeding the actual image dimensions.

Having selected a rectangular frame to cut, the next step is to divide that frame into six parts (sextants). After a meeting with the radiologist, it was decided to divide the lungs into sextants *evenly by area of mask*. Thus, the cropping frame is first divided vertically into three equal parts according to the mask area (two horizontal lines in fig. 5), so the area of each part should be one-third of the area of the whole lung mask. The cropping frame is then divided exactly in half horizontally (one vertical line in fig. 5). An approach involving overlapping sextants could potentially provide better performance. The investigation of overlapping sextant configurations is intended for future research.

To correctly process masks with one lung (514 images of column 1 in tabl. 1), a second missing lung must be drawn on the image. Fig. 6 shows how the cropping frame is formed around the mask for the case where only one lung (contour) was detected on the CXR image.

In fig. 6 value d is the estimated distance between existing and missing lungs and W_1 is the width of one lung mask. To find the estimated value of d , we obtained all masks with (at least) two contours and found the ratio k of the distance between the lungs (the two largest contours) to the sum of the widths of the two lungs using eq. (1):

$$k = \frac{d}{W_1 + W_2}, \quad (1)$$

where d is the distance between the two lungs; W_1 is the width of the right lung; W_2 is the width of the left lung. Fig. 7 explains the variables in eq. (1).

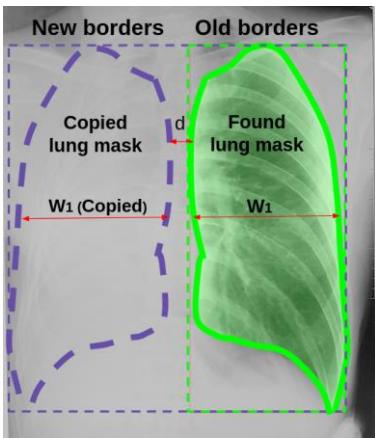


Fig. 6. An image explaining the procedure for selecting the cropping frame for a single lung

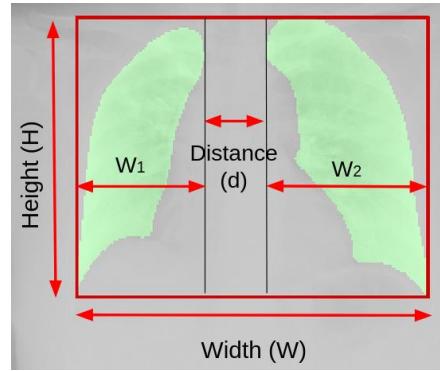


Fig. 7. Image explaining the notations in the eq. (1)

Tabl. 2 shows the results of the calculated k ratio in eq. (1) among the original CXR dataset.

Table 2
 Number of images with value k in the intervals

Number of images	10,118	30	9	4	1
Interval of k values	(0, 0.3]	(0.3, 0.4]	(0.4, 0.5]	(0.5, 0.6]	(0.6, 0.7]

According to tabl. 2, most of the images that have at least two contours on the mask have a k value between 0 and 0.3 (over 99.5% of all images). The average value of the k over the whole dataset is 0.079. Thus, it was decided to use a k value equal to 0.3 to construct a cropping frame with a missing lung. This choice is due to the intention to preserve more information in the image when the cropping frame is automatically selected.

If $k = 0.3$ and according to eq. (1) the estimated value of d for one-lung mask is equal to:

$$d = k \cdot (W_1 + W_2) = k \cdot 2 \cdot W_1 = 0.6 \cdot W_1. \quad (2)$$

Therefore, if the number of lung contours is equal to one, a new cropping frame width is calculated automatically by mirroring one lung to the other half of the thorax with the missing lung. The eq. (3) for calculating the width W of the cropping frame is:

$$W = 2 \cdot W_1 + d = 2.6 \cdot W_1. \quad (3)$$

Quantitative analysis of the obtained data. An important step of this study was to collect statistical information about the existing markup of lung images based on radiologists' annotations (feature labels). All feature labels are divided into five groups:

1. general features for describing the lungs as a whole (5 features);
2. features for describing cavities in the lungs (5 features);
3. features for describing nodules in the lungs (11 features);
4. features for describing infiltrate (density anomalies) in the lungs (3 features);
5. feature to describe the presence and magnitude of pulmonary collapse (1 feature).

In total 25 features were analyzed. Unfortunately, there is no possibility to show all tables and charts in this paper. Therefore, here is an example of one labeling feature "Small Nodules" in the original CXR dataset.

The "Small Nodules" feature is the integer number from 0 to 100%. The frequency and distribution of non-empty values of the "Small Nodules" feature are shown in tabl. 3, 4, and fig. 8, 9.

Table 3
Number of lobes with non-empty values for the "Small Nodules" feature

	Upper Right lobe	Upper Left lobe
> 0	4,120	3,616
= 0	3,418	2,965
	Middle Right lobe	Middle Left lobe
> 0	2,819	2,828
= 0	2,402	2,424
	Lower Right lobe	Lower Left lobe
> 0	1,529	1,325
= 0	1,551	1,563

Table 4
Number of lobes with non-zero values in the intervals for the "Small Nodules" feature

Value range, %	(0, 10]	(10, 20]	(20, 30]	(30, 40]	(40, 50]	(50, 60]	(60, 70]	(70, 80]	(80, 90]	(90, 100]
Number of lobes	8,272	4,110	1,325	1,123	651	276	189	168	50	73

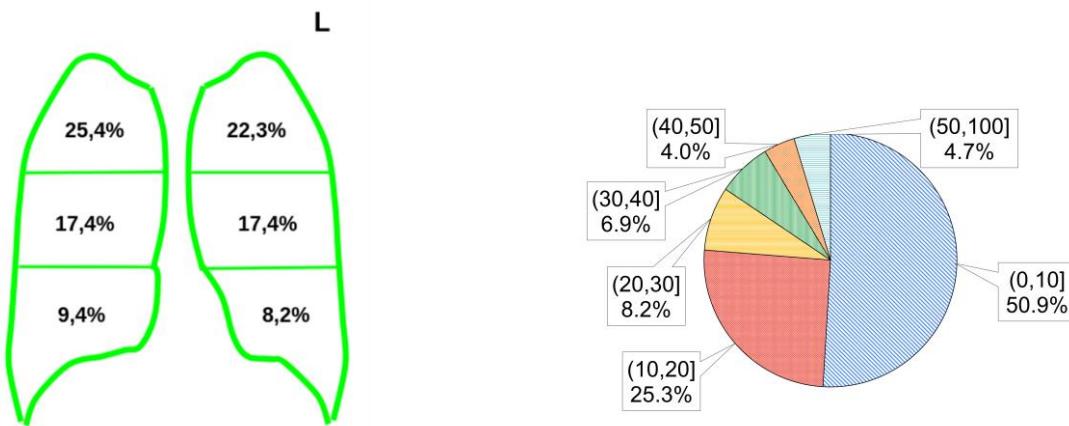


Fig. 8. Percentage distribution of lobes with non-zero values for the "Small Nodules" feature

Fig. 9. Frequency of occurrence of lobes with non-zero values for the "Small Nodules" feature

Based on the quantitative analysis of the data obtained, the following conclusions can be drawn.

A *strong imbalance* in the annotated data was found when working with different groups of feature labels. This strong imbalance exists for both the distribution of binary responses ("Yes" or "No") and for integer numerical values from 0 to 100%.

For binary responses ("Yes" or "No"), most data have a value of "No".

For integer numerical values from 0 to 100%, most non-zero data is in the range [1, 10]% and zero values are the most common.

Upper sextants are affected more frequently than lower sextants. The right lung is affected generally more frequently than the left lung. The exception is only the "Collapse" feature, for which lower sextants are affected more frequently than upper sextants, and the right-left distribution is approximately the same.

The lack of labeled data can be partially addressed by *merging data for different sextants into one group*. Thus, circumventing the lack of data for training. To increase the training dataset size, we merged data with the same labels for the upper right/left, middle right/left, and lower right/left sextants into one group.

As a result of data merging, the task of recognizing lesions in lung lobes is reduced from regression (predict a number) to binary (a class exists or does not exist in the lung). Thus, in tabl. 5, the labeling features are combined from the 20 tasks into three binary tasks.

Table 5
 Three binary classification tasks for cavities, nodules, and infiltrates

Feature name [6]	Value range	Task
1. Small Cavities (less than 3 cm)	[0.0, 100.0]%	Reduce to the binary classification task. Cavities exist or don't exist in a sextant
2. Medium Cavities (3–5 cm)	[0.0, 100.0]%	
3. Large Cavities (more than 5 cm)	[0.0, 100.0]%	
4. Does any Large cavity belong to a multi-sextant cavity?	Yes / No	
5. Can Multiple cavities be seen?	Yes / No	
6. Small Nodules (less than 3 mm)	[0.0, 100.0]%	Reduce to the binary classification task. Nodules exist or don't exist in a sextant
7. Medium Nodules (5–15 mm)	[0.0, 100.0]%	
8. Large Nodules (15–30 mm)	[0.0, 100.0]%	
9. Huge Nodules (more than 30 mm, tuberculoma)	[0.0, 100.0]%	
10. Any calcified or partially-calcified Nodules?	Yes / No	
11. Any non-calcified Nodules?	Yes / No	Reduce to the binary classification task. Infiltrates exist or don't exist in a sextant
12. Any clustered Nodules (nodules 2–5 mm apart)?	Yes / No	
13. Can Multiple Nodules be seen?	Yes / No	
14. Low/ground glass Density (active fresh nodules)	[0.0, 100.0]%	
15. Medium Density (stabilized fibrotic nodules)	[0.0, 100.0]%	
16. High Density (calcified nodules, typically sequella)	[0.0, 100.0]%	Not considered
17. Low/ground glass Density	[0.0, 100.0]%	
18. Medium Density	[0.0, 100.0]%	
19. High Density	[0.0, 100.0]%	
20. Collapse	[0.0, 100.0]%	

Collapse is not considered, because it is easily detected visually even by a non-specialist.

Five general features for describing the lungs as a whole are not considered in this research, because we only work with lobes here.

Creating training, validation, and testing datasets. If different lung lobes from the same patient are both in the training and test datasets, this will lead to overtraining of the neural network and overestimation of classification accuracy. To exclude different fragments of the same patient in the training and test datasets all CXR images were divided into three groups according to patient ID: training (70% of all patient IDs), validation (15%), and testing (15%). That is, each ID should belong only to the training, validation, or testing dataset.

Dataset directories for training, validation, and testing were created using the algorithm in fig. 10.

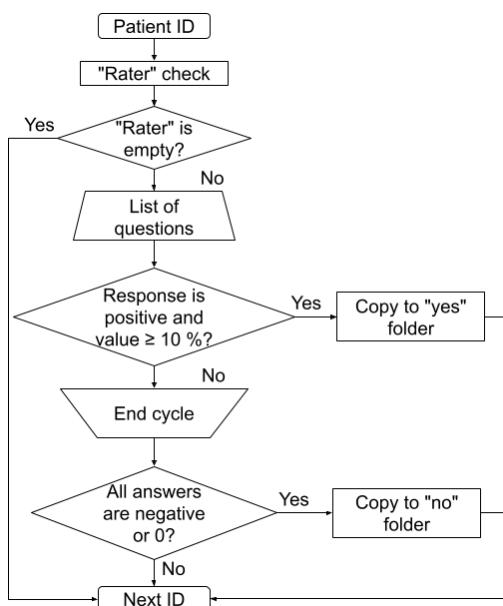


Fig. 10. Algorithm for creating datasets

The algorithm presented in fig. 10 includes two main checks.

1. Verification that an expert has annotated the lungs. By checking the "Rater" field in "Overall Characteristics" is not empty. If the "Rater" field is empty, the CXR image is not annotated and is excluded from datasets.

2. Division of lung sextants into classes according to various conditions. For example, separation into a "cavity" class in the "yes" directory and a "not cavity" class in the "no" directory.

Conducting experiments. During the initial experiments, the following neural network architectures have been trained and tested: Xception, InceptionResNetV2, EfficientNet (B0, B1, B2, B3, B5), DenseNet (121, 169, 201), MobileNet (V2, V3Small). Various hypotheses were tested for the data and hyperparameters of the neural networks.

In this study, the following hyperparameters were used during training: the models were trained for a total of 150 epochs with a batch size of 5, optimization was performed using the Adam optimizer with an initial learning rate of 0.00001, and the learning rate was scheduled to decay exponentially with a decay rate of 0.96 every 10,000 steps. Additionally, early stopping with a patience of 15 epochs was applied to prevent overfitting and ensure efficient convergence.

As an example, tabl. 6 shows the classification accuracy for the nodule lesions with the final terms for the data described below.

Table 6
Classification accuracy for the nodule lesions on the test dataset

Neural network architecture	Classification accuracy for the <i>nodule</i> lesion on the test dataset, %	Number of trainable parameters, mln	Number of epochs to train
Xception	72.7 / 72.8 / 72.4 / 71.8 / 72.1 / 72.7	20.8	17 / 16 / 20 / 19 / 17 / 19
InceptionResNetV2	72.4 / 72.3	54.3	20 / 28
DenseNet201	72.8 / 72.9	18.1	50 / 39
DenseNet169	73.2 / 73.6 / 73.4	12.5	54 / 41 / 55
EfficientNetB5	62.7 / 65.9 / 66.2	28.3	43 / 48 / 65
EfficientNetB3	66.2	10.7	49
EfficientNetB0	69.5	4.0	121
MobileNetV2	71.1 / 70.1	2.2	121 / 131
MobileNetV3Small	63.4	1.5	16

Some architectures have multiple training sessions separated by a "/" sign.

For tabl. 6 the datasets for training, validation, and testing are the same, as well as all the hyperparameters of the neural network. The difference is in the architecture, in the preliminary shuffle of the data, and the random augmentation.

Both lightweight and large architectures to test the accuracy and heat maps were used. The accuracy difference between *training sessions of the same architecture* is approximately $\pm 0.5\%$, i.e., for Xception $72.8 - 71.8 = 1.0$ and $1.0/2 = \pm 0.5$.

According to tabl. 6, there is an accuracy difference between architectures from 62.7 to 73.6% or around 10.9% which is a large percentage for binary classification. Generally, large architectures with more trainable parameters give higher accuracy, but this is not always the case. For example, MobileNetV2 either very fast and has an accuracy that is comparable to architectures 10 times larger. MobileNetV2 is not the best in terms of accuracy, but when speed is also important, this neural network is indispensable.

Oddly enough, EfficientNetB5 with 28.3 million trainable parameters performs much worse (66.2% for the third training session) than its counterpart EfficientNetB0 with 4.0 million parameters (69.5%). *No signs of overfitting were observed for EfficientNetB5.* Training took 65 epochs and *validation* accuracy did not exceed 66.6%, which corresponds to minimal validation loss in the early stopping callback checkpoint with the patience of 15 epochs.

As a result of numerous workouts with different architectures and hyperparameters of these architectures, we decided to stop at Xception architecture [11]. Although DenseNet169 performed slightly better. *In this study, we focus not on architecture but on the data itself and the reasons how to raise the accuracy above 75% in future research.*

The quality of the resulting heat maps is important because visualization of the lesions is also the goal of the study. Not all neural networks produce consistent results that can be interpreted by medical professionals. For example, EfficientNet models showed useless heat maps because of the nature of their architecture. DenseNet models also showed poorly interpretable heat maps. Later, the following sections present radiologist-verified heat maps for each identified type of pathology.

We would like to note that similar results were obtained by another team when solving the problem of COVID-19 search on X-ray images [12]. According to their results, Xception architecture is also best for classification tasks.

In general, the following conversions and improvements to make datasets were made:

– randomly divide patient IDs into three categories: training (70% of all patient IDs), validation (15%), and testing (15%), so different sextants of the same patient cannot be in both the training and test datasets;

- CXR image evaluator (rater) must be non-empty;
- remove from the dataset all annotations whose value is less than or equal to 10% ($\leq 10\%$);
- apply various augmentations to the images;
- normalize images to the range $[-1, 1]$;
- equalize the datasets so that the number of "yes" and "no" cases are equal;
- convert from float32 to float16 to make dataset smaller;
- apply checkpoints with early stopping to minimize loss value;
- etc.

Two main improvements significantly enhanced classification accuracy: data augmentation and filtering out *data values less than or equal to 10% ($\leq 10\%$)*. Other modifications had minimal impact on performance.

The decision to remove values $\leq 10\%$ was based on observed improvements in classification accuracy. In our dataset, the values represent numeric annotations assigned by the radiologist to different regions of the image. However, many of these values fell within the low range $(0, 10]\%$ and appeared to contribute little meaningful information.

For example, as shown in fig. 9, the "Small Nodules" label included 50.9% of non-zero values within the $(0, 10]\%$ range. Despite their high frequency, removing these low values improved accuracy by reducing noise and highlighting more relevant areas.

To evaluate this effect, we conducted several experiments using the Xception architecture:

1. accuracy on test data with values $> 10\% = 72.8\%$;
2. accuracy on full-range test data $(0-100]\% = 70.9\%$;
3. accuracy on test data with values $> 20\% = 70.4\%$.

The difference between the first and second results is 1.9%, indicating that excluding low values has a measurable positive impact. While the exact reason for this improvement is not fully understood, we suspect that values $\leq 10\%$ may introduce noise or inconsistencies into the model's predictions. Further investigation – ideally involving domain experts such as radiologists – would help clarify this.

Further removal of values less than or equal to 20% reduces classification accuracy by about 2%. The test dataset in the second check also contains data $> 10\%$. In future research, it will be interesting to train on $> 10\%$ data but evaluate on $(0, 100]\%$ data.

Properly done augmentation almost always enhances results. In this study, augmentation improved accuracy by about 3%. Augmentation consists of:

- random horizontal and vertical flips;
- three random rotations on 90, 180, and 270 degrees;
- random brightness change within $\pm 5\%$;
- small random contrast change.

In addition, nodule lesions were divided into "small-medium" and "large-huge" subclasses (see rows 6–9 in tabl. 5) to test the hypothesis that on divided subgroups the neural network binary classification will be better (fig. 11).

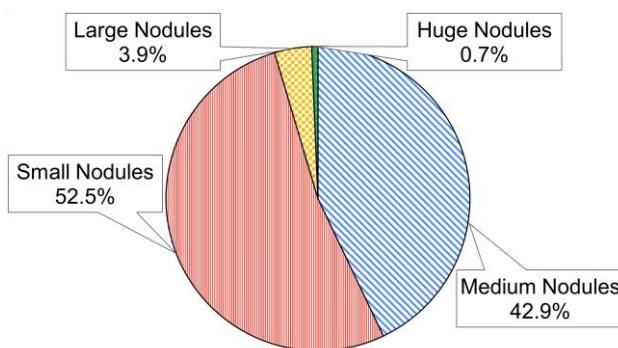


Fig. 11. Percentage of nodules sizes

However, this did not give a significant improvement:

- for "small-medium" nodules size (5,955 images in total) Xception accuracy is 76.59%;
- "large-huge" nodules size (287 images in total) Xception accuracy is 64.37%.

In comparison for all nodule sizes in one class, the accuracy is 72.83%. Here "large-huge" has lower accuracy than "small-medium". *This is counterintuitive*, because "large-huge" nodules should be more visible. We assume there is not enough data for "large-huge" nodules to train a neural network.

The classification accuracy achieved on the test datasets for cavities, infiltrates, and nodules is presented in the respective sections below. Importantly, none of the test samples were used during the training of the neural network. A detailed performance evaluation across individual classes is provided in the confusion matrices shown in tabl. 8, 10, 12.

Cavities detection. The dataset size for cavities detection to train neural networks is shown in tabl. 7.

Table 7
Dataset size for cavities detection to train neural networks

Class name	Training	Validation	Test
"Yes" or cavities are present	2,476	387	553
"No" or cavities are absent	2,476	387	553
Total	4,952	774	1,106

Five feature labels were used to create the dataset (see rows 1–5 in tabl. 5). At least one non-zero value or affirmative ("Yes") feature label is sufficient to assign the lung lobe image to the "Yes" class with some cavities in the image (see the algorithm in fig. 10). For the second "No" class or without cavities in the image all five features are required to have zero or negative answers. The same approach is applied to infiltrates and nodules but with different feature labels.

Classification accuracy for the test dataset is 73.1%.

Table 8
Confusion matrix for cavities binary classification

		Actual	
		Positive (with cavities)	Negative (without cavities)
Predicted	Positive	TP=408	FP=153
	Negative	FN=145	TN=400

In comparison, random guessing has an accuracy of 50%. Thus, the obtained accuracy of 73.1% is good. Incorrect neural network predictions: false negative (FN=145) and false positive (FP=153) are roughly comparable. In medicine, FN is more significant than FP and should be smaller ($FN < FP$), because missing an illness can cost a life. However, we have not explored this issue in depth.

Fig. 12 shows heat maps for the true positive (TP) responses automatically obtained by the neural network on the test dataset.

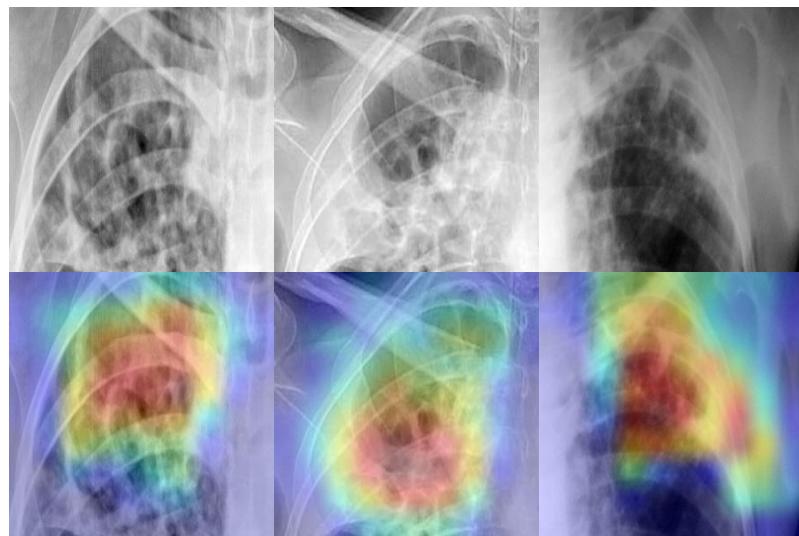


Fig. 12. Examples of TP outcomes for cavities and corresponding heat maps

The correctness of the heat maps in fig. 12 was agreed with the radiologist.

Infiltrates (anomalous density) detection. The dataset size for infiltrates detection to train neural networks is shown in tabl. 9.

Table 9
 Dataset size for infiltrates (anomalous density) detection to train neural networks

Class name	Training	Validation	Test
"Yes" or infiltrates are present	4,935	1,120	977
"No" or infiltrates are absent	4,935	1,120	977
Total	9,870	2,240	1,954

Three feature labels were used to create the dataset (see rows 17–19 in tabl. 5). Classification accuracy for the test dataset is 71.9%.

Table 10
 Confusion matrix for infiltrates binary classification

		Actual	
		Positive (with infiltrates)	Negative (without infiltrates)
Predicted	Positive	TP=730	FP=302
	Negative	FN=247	TN=675

Fig. 13 shows heat maps for the TP responses automatically obtained by the neural network on the test dataset.

The radiologist's expertise revealed that the neural network correctly identified the presence of the infiltrates in fig. 13, but their location on the heat map is not where the red color is located.

The approximate location of the infiltrate is highlighted by the non-radiologist in fig. 13, b.

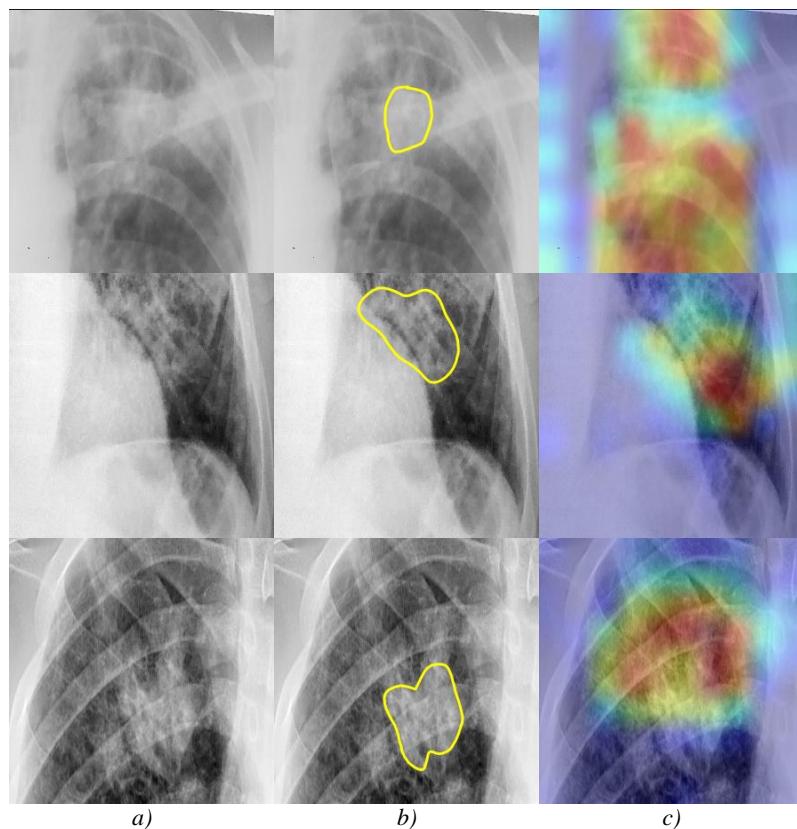


Fig. 13. Examples of TP outcomes for infiltrates: a) unlabeled input images; b) approximate ground truth; c) corresponding heat map

If compare the heat map and the approximate location of the infiltrate, we can conclude that the *neural network pays attention not to the infiltrate itself (the light spot), but to the gradient*, i.e., the transition from less dense to more dense areas at the infiltrate boundary. The areas from lower to higher density (gradients) are highlighted by the neural network, but not the infiltrate itself.

Nodules detection. The dataset size for nodules detection to train neural networks is shown in tabl. 11.

Table 11
Dataset size for nodules detection to train neural networks

Class name	Training	Validation	Test
"Yes" or nodules are present	8,834	2,006	1,796
"No" or nodules are absent	8,834	2,006	1,796
Total	17,668	2,012	3,592

Eleven feature labels were used to create the dataset (see rows 6–16 in tabl. 5). Classification accuracy for the test dataset is 72.8%.

Table 12
Confusion matrix for nodules binary classification

		Actual	
		Positive (with nodules)	Negative (without nodules)
Predicted	Positive	TP=1,218	FP=402
	Negative	FN=578	TN=1,394

Fig. 14 shows heat maps for the TP responses automatically obtained by the neural network on the test dataset.

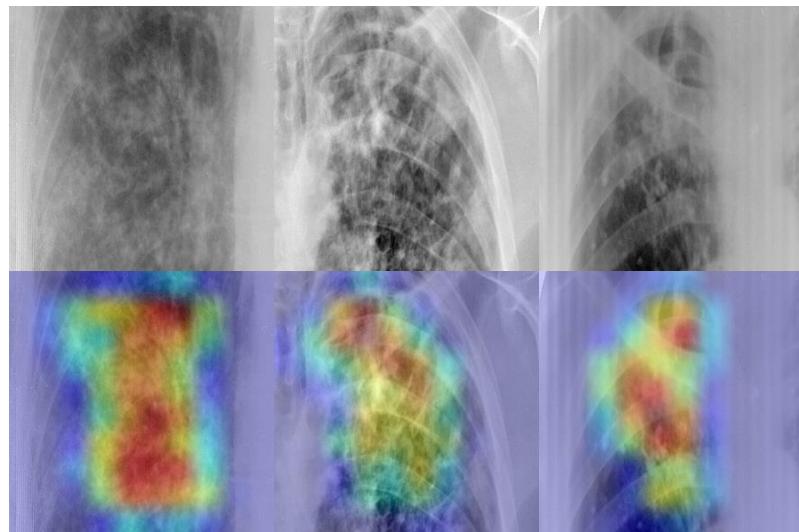


Fig. 14. Examples of TP outcomes for nodules and corresponding heat maps

The correctness of the heat maps in fig. 14 was agreed with the radiologist.

Discussion of results. The average classification accuracy of the Xception model for three lesion types: cavities (73.1%), infiltrates (71.9%), and nodules (72.8%), is equal to 72.6%.

Three improvements made the greatest contribution to accuracy:

- filtering of data by numerical values greater than 10% ($>10\%$);
- excluding images with empty "Rater" field in "Overall Characteristics";
- image augmentation.

Overall, classification accuracy improved by an average of 5%.

It was found that *classification errors in all three lesion types are primarily related to the quality of the original dataset*. That's why it's hard to improve accuracy over 75%.

It was observed that some unlabeled sextants, in which the lung lobe should be free of lesions, were classified as pathological by the neural network. For example, according to the radiologist, sextants in fig. 15 and fig. 16 contain lesions, and the neural network shows they are, but they didn't contain any markup in the dataset and are considered as healthy.

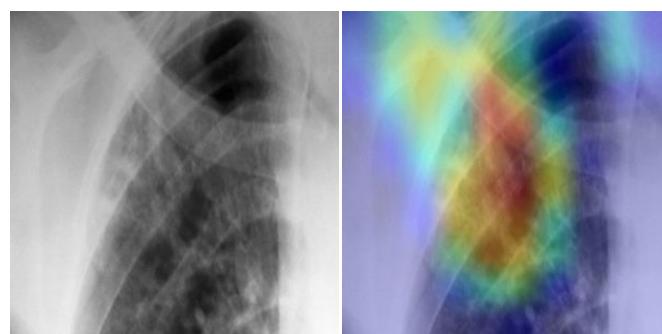


Fig. 15. There are nodules in the image, but they are not present in the annotated data

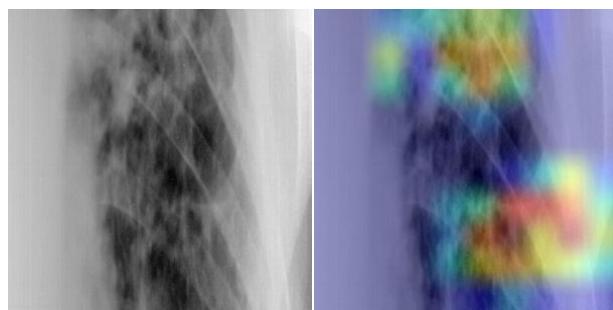


Fig. 16. There are cavities in the image, but they are not present in the annotated data

Another cause of classification errors is poor image quality in some cases. For example, in fig. 17, the misclassification result is affected by the low image contrast and the presence of artifacts in the background.

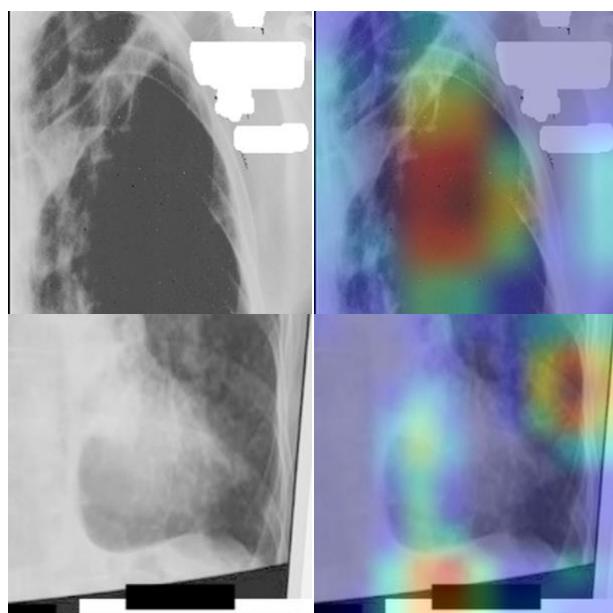


Fig. 17. Examples of low-quality images with FP outcome

Heat maps from the Xception model with TP outcomes for cavities and nodules are mostly understandable to radiologists.

Heat maps for infiltrates (see fig. 13) are not understandable to radiologists because the area of attention of the neural network is not directed to the area of pathology itself. Instead, the neural network pays attention to gradients or the area of transition from healthy tissue to pathology around or near the infiltrate. This may be because an infiltrate is an area of the lung with a higher density and appears as a lighter area on the CXR image. For this reason, infiltrate can be seen by analyzing changes in the brightness of the image (gradients), which is what the neural network does.

To get heat maps for infiltrate (anomalous density) that are understandable to experts, a separate study should be done. The most likely approach is to make preliminary gradient transformations of the CXR images to produce heat maps with the correct location of red regions.

From the perspective of radiologists, the classification of infiltrates represents a particularly challenging diagnostic task. We also had difficulties visualizing the infiltrate using heat maps. It was unexpected to get the result that the neural network pays attention during classification not to the lesion itself, but to the gradient area around it.

It is our contention that the following additional studies will serve to enhance the accuracy of the classification and the quality of the heat maps.

1. Using only digital images (cell phone photos must be excluded) should greatly improve the results.

2. Advanced data selection depending on various conditions would presumably improve the results.

3. Prepare a dataset based on descriptors labeled (annotated) by a single expert. And then fine-tune the trained model on this dataset. This method can improve the classification accuracy since the methodology of labeling images by one expert is the same.

4. Our team from Belarus annotated many three-dimensional CT images. CT is not CXR (different modality). Nevertheless, it is theoretically possible to obtain additional valuable descriptors that describe the position of the studied lesions (cavities, nodules, and infiltrate). For example, convert CT to CXR modality and apply the available CT annotations to increase the spatial accuracy predictions of the neural network for CXR scans.

Conclusions. For the Xception model, the binary classification accuracy on the test dataset is 73.1% for cavities, 71.9% for infiltrates, and 72.8% for nodules.

Heat maps associated with pathological processes in the lungs were constructed. Heat maps with true positive outcomes for cavities and nodules are mostly understandable to experts. To get heat maps for infiltrates that are understandable to experts, more research is needed.

Obtained results are good, but not excellent. Further investigation should be done to improve the classification accuracy and quality of the heat maps.

Authors' contributions. D. A. Paulenka carried out the quantitative analysis of the obtained data and conducted experimental studies, including training and testing models for nodule lesions. A. A. Kosareva proposed an algorithm for dividing the lung into sextants, created training, validation, and testing datasets of sextants from the original CXR database of the TB Portals Case Browser, and conducted experimental studies, including training and testing models for cavity and infiltrate lesions. E. V. Senezhko provided scientific supervision for the overall research process and conducted a literature review on the topic. V. A. Kovalev participated in discussions, summarization, and presentation of the obtained results.

References

1. Hansun S., Argha A., Liaw S.-T., Celler B. G., Marks G. B. Machine and deep learning for tuberculosis detection on chest X-rays: systematic literature review. *Journal of Medical Internet Research*, 3 July 2023, vol. 25, p. e43154. DOI: 10.2196/43154.
2. Acharya V., Dhiman G., Prakasha K., Bahadur P., Choraria A., ..., Kautish S. AI-assisted tuberculosis detection and classification from chest X-rays using a deep learning normalization-free network model. *Computational Intelligence and Neuroscience*, 3 October 2022, vol. 2022, p. 2399428. DOI: 10.1155/2022/2399428.
3. Guo R., Passi K., Jain C. K. Tuberculosis diagnostics and localization in chest X-rays via deep learning models. *Frontiers in Artificial Intelligence*, 5 October 2020, vol. 3, p. 583427. DOI: 10.3389/frai.2020.583427.
4. Thomsen K., Christensen A. L., Iversen L., Lomholt H. B., Winther O. Deep learning for diagnostic binary classification of multiple-lesion skin diseases. *Frontiers in Medicine*, 2020, vol. 7, p. 574329. DOI: 10.3389/fmed.2020.574329.
5. Selvaraju R. R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: visual explanations from deep networks via gradient-based localization. *International Journal of Computer Vision*, October 2019, vol. 128, no. 2, pp. 336–359. DOI: 10.1007/s11263-019-01228-7.
6. Rosenthal A., Gabrielian A., Engle E., Hurt D. E., Alexandru S., ..., Tartakovsky M. The TB Portals: an open-access, web-based platform for global drug-resistant-tuberculosis data sharing and analysis. *Journal of Clinical Microbiology*, 2017, vol. 55, no. 11, pp. 3267–3282. DOI: 10.1128/jcm.01013-17.
7. Gabrielian A., Engle E., Harris M., Wollenberg K., Juarez-Espinosa O., ..., Tartakovsky M. TB DEPOT (Data Exploration Portal): A multi-domain tuberculosis data analysis resource. *PLOS ONE*, May 2019, vol. 14, no. 5, pp. 1–23. DOI: 10.1371/journal.pone.0217410.
8. Kosareva A., Paulenka D., Senezhko E. Chest X-ray image processing based on radiologists' textual annotations. *Open Semantic Technologies for Intelligent Systems (OSTIS): Conference Proceedings*, Minsk,

Belarus, 18–20 April 2024. Editorial board: V. V. Golenkov [et al.]. Belarusian State University of Informatics and Radioelectronics, vol. 8, pp. 293–302.

9. Snezhko E. V., Kovalev V. A., Kosareva A. A., Paulenka D. A. AI-based software for computer-assisted diagnosis of lung diseases using chest X-Ray and CT images. *The 1st Exhibition-forum of the IT-academgrad "Artificial Intelligence in Belarus": Conference Proceedings, Minsk, 13–14 October 2022*, pp. 80–87 (In Russ.).
10. Kovalev V. A., Tuzikov A. V., Snezhko E. V., Paulenka D. A. Software "AI-based software for computer-assisted diagnosis of lung diseases using chest X-Ray and CT images" (LungExpert). *Computer program registration certificate No. 1619 dated 02.08.2023* (In Russ.). Available at: <http://search.ncip.by/depon/index.php?pref=1&lng=ru&page=3&target=1771> (accessed 15.09.2024)
11. Chollet F. Xception: deep learning with depthwise separable convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 21–26 July 2017*, pp. 1251–1258.
12. Nillmani, Sharma N., Saba L., Khanna N., Kalra M., ..., Suri J. Segmentation-based classification deep learning model embedded with explainable AI for COVID-19 detection in chest X-ray scans. *Diagnostics*, September 2022, vol. 12, p. 2132. DOI: 10.3390/diagnostics12092132.

Information about the authors

Dzmitry A. Paulenka, Postgraduate Student, Lead Software Engineer, Laboratory of Biomedical Images Analysis, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.

E-mail: dmitri.pavlenko@gmail.com
<https://orcid.org/0009-0007-9911-4356>
<https://www.researchgate.net/profile/Dzmitry-Paulenka>
<https://scholar.google.com/citations?user=2AX0it0AAAAJ>

Aleksandra A. Kosareva, Junior Researcher, Laboratory of Biomedical Images Analysis, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.

E-mail: kosarevaaleksandra4317@gmail.com
<https://www.researchgate.net/profile/Alexandra-Kosareva-3>
<https://www.scopus.com/authid/detail.uri?authorId=57934126700>

Eduard V. Snezhko, Ph. D. (Eng.), Head of the Laboratory of Biomedical Images Analysis, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.

E-mail: eduard.snezhko@gmail.com
<https://orcid.org/0000-0002-9843-0839>
<https://www.researchgate.net/profile/Eduard-Snezhko>

Vassili A. Kovalev, Ph. D. (Eng.), Leading Researcher, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.

E-mail: vassili.kovalev@gmail.com
<https://orcid.org/0000-0002-8154-5875>
<https://www.researchgate.net/profile/Vassili-Kovalev-2>
<https://scholar.google.com/citations?user=-osN7dIAAAJ>

Информация об авторах

Павленко Дмитрий Анатольевич, аспирант (соискатель), ведущий инженер-программист, лаборатория анализа биомедицинских изображений, Объединенный институт проблем информатики Национальной академии наук Беларусь.

E-mail: dmitri.pavlenko@gmail.com
<https://orcid.org/0009-0007-9911-4356>
<https://www.researchgate.net/profile/Dzmitry-Paulenka>
<https://scholar.google.com/citations?user=2AX0it0AAAAJ>

Косарева Александра Андреевна, младший научный сотрудник, лаборатория анализа биомедицинских изображений, Объединенный институт проблем информатики Национальной академии наук Беларусь.

E-mail: kosarevaaleksandra4317@gmail.com
<https://www.researchgate.net/profile/Alexandra-Kosareva-3>
<https://www.scopus.com/authid/detail.uri?authorId=57934126700>

Снежко Эдуард Витальевич, кандидат технических наук, заведующий лабораторией анализа биомедицинских изображений, Объединенный институт проблем информатики Национальной академии наук Беларусь.

E-mail: eduard.snezhko@gmail.com
<https://orcid.org/0000-0002-9843-0839>
<https://www.researchgate.net/profile/Eduard-Snezhko>

Ковалев Василий Алексеевич, кандидат технических наук, ведущий научный сотрудник, Объединенный институт проблем информатики Национальной академии наук Беларусь.

E-mail: vassili.kovalev@gmail.com
<https://orcid.org/0000-0002-8154-5875>
<https://www.researchgate.net/profile/Vassili-Kovalev-2>
<https://scholar.google.com/citations?user=-osN7dIAAAJ>



УДК 004.89
DOI: 10.37661/1816-0301-2025-22-3-25-34

Оригинальная статья
Original Article

Система транскрибации речи и перевода с русского языка на китайский

Л. П. Кузьменков, В. А. Чуйко, Е. И. Козлова[✉]

Белорусский государственный университет,
пр. Независимости, 4, Минск, 220030, Беларусь
[✉]E-mail: kozlova@bsu.by

Аннотация

Цели. Целью проведенной работы является разработка архитектуры информационной системы для транскрибации и перевода речи, реализация ее блоков и тестирование их работы.

Методы. Рассмотрены существующие способы распознавания речи, проведен сравнительный анализ моделей распознавания речи и перевода текста. Процесс транскрибации речи включает в себя несколько последовательных этапов: сбор и предварительную обработку аудиосигнала, извлечение акустических признаков, непосредственное распознавание речи, постобработку и коррекцию текста, вывод результата. На этапе предобработки аудиосигнала используется комбинация специализированных библиотек, обеспечивающих подготовку данных для последующего анализа. Для нормализации параметров записи применяется библиотека librosa, позволяющая выполнять передискретизацию сигнала до стандартной частоты 16 кГц и преобразование его в монофонический формат. Для подавления фоновых шумов и выделения речевого компонента задействуется нейросетевая модель Demucs. Алгоритм спектральной субтракции дополнительно корректирует остаточные шумы. Сегментация речевой активности выполняется с использованием энергетического детектора из WebRTC, автоматически выделяя речевые фрагменты и удаляя паузы. Для реализации системы распознавания речи выбрана модель whisper-turbo (OpenAI) ввиду большей скорости обработки данных, позволяющей реализовывать потоковый режим работы системы, и меньших требований к вычислительной мощности машины. Модуль перевода разработанной интеллектуальной системы построен на модели T5-large-1024 (Text-to-Text Transfer Transformer), адаптированной для многоязычных задач.

Результаты. Предложен способ создания интеллектуальной системы распознавания речи – модульная архитектура системы распознавания и перевода речи, реализован прототип и замерены метрики. Система показала следующие результаты: для русско-английского перевода Cosine Similarity 0,6951, WER 0,529, BLEU Score 0,239; для каскадного русско-китайского перевода через английский язык Cosine Similarity 0,557, WER 0,748, BLEU Score 0,095. Исследования доказали, что применение каскадного перевода через английский язык повышает качество итогового текста на 32 % по метрике Cosine Similarity и на 25 % по BLEU Score по сравнению с прямым переводом. Результаты работы реализованного прототипа оказались удовлетворительными.

Заключение. Предложенная реализация системы распознавания речи может решать поставленную задачу с удовлетворительным для описанной проблемы качеством без рисков несанкционированного доступа к данным, поскольку работает без подключения к сети интернет. При использовании каскадного перевода через английский язык качество русско-китайского перевода улучшается на 32 % по метрике Cosine Similarity (с 0,423 до 0,557) и на 25 % по метрике BLEU Score (с 0,076 до 0,095). Предложенная информационная система может быть внедрена в образовательный процесс вне зависимости от учебной дисциплины, а также применена на выставках, конференциях, международных форумах. Возможен параллельный перевод на различные языки, что позволит всем участникам международных форумов активно участвовать в мероприятиях.

Ключевые слова: информационная система, агент, декодер, энкодер, трансформер, сверточные нейронные сети, транскрибация и перевод речи

Для цитирования. Кузьменков, Л. П. Система транскрибации речи и перевода с русского языка на китайский / Л. П. Кузьменков, В. А. Чуйко, Е. И. Козлова // Информатика. – 2025. – Т. 22, № 3. – С. 25–34. – DOI: 10.37661/1816-0301-2025-22-3-25-34.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 08.07.2025

Подписана в печать | Accepted 23.07.2025

Опубликована | Published 30.09.2025

Speech transcription and translation system from Russian to Chinese

Leonid P. Kuzmenkov, Vladislav A. Chuyko, A. I. Kazlova[✉]

*Belarusian State University,
av. Nezavisimosti, 4, Minsk, 220030, Belarus
✉E-mail: kozlova@bsu.by*

Abstract

Objectives. The aim of the work is to develop the architecture of an information system for transcription and translation of speech, implement its blocks and test their operation.

Methods. The existing methods of speech recognition are considered; a comparative analysis of speech recognition and text translation models is carried out. The speech transcription process includes several successive stages: collection and preliminary processing of the audio signal, extraction of acoustic features, direct speech recognition, post-processing and text correction, and output of the result. At the stage of audio signal pre-processing, a combination of specialized libraries is used to prepare data for subsequent analysis. To normalize the recording parameters, the Librosa library is used, which allows resampling the signal to a standard frequency of 16 kHz and converting it to a monophonic format. To suppress background noise and highlight the speech component, the Demucs neural network model is used. The spectral subtraction algorithm additionally corrects residual noise. Speech activity segmentation (VAD) is performed using an energy detector from WebRTC, automatically highlighting speech fragments and removing pauses. The whisper-turbo (OpenAI) model was chosen to implement the speech recognition system due to the higher data processing speed, which allows implementing the streaming mode of the system, and lower requirements for the computing power of the machine. The translation module of the developed intelligent system is built on the T5-large-1024 (Text-to-Text Transfer Transformer) model, adapted for multilingual tasks.

Results. A method for creating an intelligent speech recognition system is proposed - a modular architecture of the speech recognition and translation system, a prototype is implemented and metrics are measured. The system showed the following results: for Russian-English translation Cosine Similarity 0.6951, WER 0.529, BLEU Score 0.239; for cascade Russian-Chinese translation through English Cosine Similarity 0.557, WER 0.748, BLEU Score 0.095. Research has shown that the use of cascade translation through English improves the quality of the final text by 32% according to the Cosine Similarity metric and by 25% according to BLEU Score compared to direct translation. The results of the implemented prototype were satisfactory.

Conclusion. The proposed implementation of the speech recognition system can solve the task with quality satisfactory for the described problem without risks of unauthorized access to data, since it works without an Internet connection. When using cascade translation through English, the quality of Russian-Chinese translation improves by 32% according to the Cosine Similarity metric (from 0.423 to 0.557) and by 25% according to BLEU Score (from 0.076 to 0.095). The proposed information system can be implemented in the educational process regardless of the academic discipline, and also used at exhibitions, conferences, and international forums. Parallel translation into different languages is possible, which will allow all participants of international forums to actively participate in its events.

Keywords: information system, agent, decoder, encoder, transformer, convolutional neural networks, speech transcribing and translation

For citation. Kuzmenkov L. P., Chuyko V. A., Kazlova A. I. *Speech transcription and translation system from Russian to Chinese*. Informatika [Informatics], 2025, vol. 22, no. 3, pp. 25–34 (In Russ.). DOI: 10.37661/1816-0301-2025-22-3-25-34.

Conflict of interest. The authors declare of no conflict of interest.

Введение. В условиях активного развития международного сотрудничества в сфере образования ограничивающим фактором для увеличения числа зарубежных студентов является нехватка преподавателей, знающих язык, который доступен для понимания иностранцам. Одним из способов решения этой проблемы служит информационная система, состоящая из модуля, транскрибирующего речь, и модуля, осуществляющего перевод. Данные модули являются агентами, а система – многоагентной. Многоагентная система – это система, образованная несколькими взаимодействующими интеллектуальными агентами. Агент в общем смысле представляет собой любой объект, способный действовать и воспринимать информацию. Представленная в данной работе многоагентная система состоит из двух агентов: агента, преобразующего входящий аудиопоток или аудиофайл в текст на языке преподавателя, и агента, осуществляющего перевод текста, полученного от первого агента, с языка преподавателя на язык, доступный для иностранных студентов. На данный момент на рынке информационных услуг представлено множество агентов и систем.

Большинство современных сервисов для транскрибации и перевода речи, таких как Otter.AI, Beeey, Google Cloud Speech API и др., требуют подключения к интернету для выполнения своих функций. Это связано с использованием облачных технологий и нейросетей, которые обрабатывают данные на удаленных серверах. Такие подходы обеспечивают высокую точность распознавания речи, поддержку множества языков и возможность обработки сложных аудиофайлов, но делают их зависимыми от интернет-соединения. При использовании готового решения возникают различные проблемы, одна из которых – безопасность.

Существующие решения. На данный момент есть множество приложений, сайтов и сервисов для перевода текстов с одного языка на другой, некоторые из систем перевода оснащены функцией распознавания и синтеза речи: Google Translate, Speech Logger, Яндекс Переводчик, Microsoft Translator, Talkao Translate.

Ключевым недостатком перечисленных сервисов является то, что их функциональность ограничена в онлайн-режиме только переводом. Большинство сервисов не предоставляют никаких услуг без подключения к сети интернет и имеют закрытый код. При использовании сервисов с закрытым исходным кодом возникает проблема кибербезопасности пользователей. Закрытый исходный код делает невозможным проверку объемов данных, собираемых сервисом. Пользователи вынуждены доверять заявлениям компаний о политиках обработки данных без возможности проверить декларированные утверждения. Закрытые системы не позволяют быть уверенным в отсутствии сбора персональных данных пользователя. Вышеперечисленные факторы создают риски утечек и неправомерного использования информации. В частности, для функции голосового ввода в условиях активного развития методик синтеза изображений или голоса, основанных на искусственном интеллекте (дипфейк), проблема утечек персональных и авторских данных крайне актуальна. Для демонстрации примера описанной выше проблемы рассматривается модель: преподаватель проводит два лекционных занятия в неделю, за месяц $9 \times 2 \text{ ч} \approx 18 \text{ ч}$. Оцененное количества данных хватило бы для обучения диффузионной модели и фальсификации речи.

Методы разработки. На рис. 1 изображена архитектура прототипа информационной системы распознавания речи. На вход интеллектуальной системы подается аудиофайл, записанный с помощью микрофона. Затем с применением библиотеки librosa производится передискретизация полученного сигнала, так как модели распознавания речи корректно работают только с аудиофайлами с определенными частотой и глубиной дискретизации. Полученный аудиофайл подается на вход модели распознавания речи. Модель распознавания речи в общем случае со-

стоит из блока извлечения признаков, энкодера и декодера. Блок извлечения признаков представлен алгоритмом преобразования непрерывного сигнала в мел-спектрограмму (спектрограмма, показывающая частотное содержание аудиосигнала во времени, представленная шкалой Мел), и сверточной нейронной сетью, используемой для понижения размерности и уменьшения вычислительных затрат на следующих этапах. Шкала Мел – это перцептивная шкала, аппроксимирующая нелинейную частотную характеристику человеческого уха.

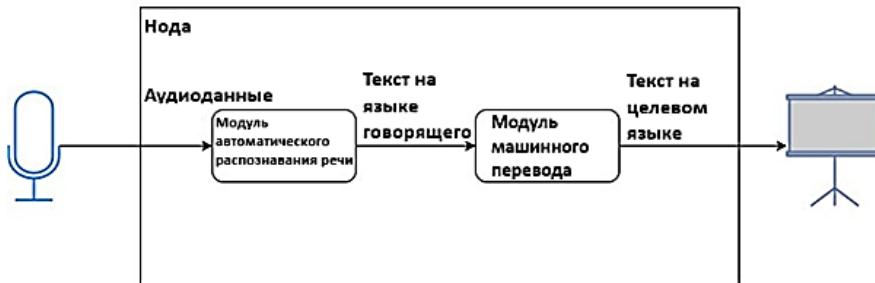


Рис. 1. Архитектура системы распознавания речи
Fig. 1. Architecture of the speech recognition system

В качестве энкодера используется трансформер или его вариации, что позволяет эффективно обрабатывать входные данные благодаря механизму многоголосового внимания и позиционному кодированию, которые учитывают контекст и последовательность токенов [1]. Декодер представлен трансформером – авторегressive моделью, основанной на архитектуре глубоких нейронных сетей. Сложная архитектура декодера, построенная на трансформерах, необходима для исправления ошибок транскрибации за счет предсказания вероятностей разных вариантов текста, который произнес человек на аудиозаписи, и выбора наиболее естественного варианта. Также существуют модели распознавания речи без энкодера, с соединенными блоками извлечения признаков, и с энкодером (например, конформер – архитектура, комбинирующая сверточные нейронные сети и механизм самовнимания).

Для оценки качества всей системы распознавания речи и отдельных агентов используются следующие метрики: косинусное подобие, алгоритм BLEU (bilingual evaluation understudy), расстояние Левенштейна (word error rate, WRE) [2]. Для получения значения косинусного подобия рассчитывается скалярное произведение векторных представлений двух текстов, полученных с помощью статической меры $tf-idf$:

$$tf-idf(t, d, D) = tf(t, d) \times idf(t, D). \quad (1)$$

Частота термина tf вычисляется по формуле

$$tf(t, d) = \frac{n_t}{\sum_k n_k}, \quad (2)$$

где n_t – число вхождений слова t в документ, а в знаменателе – общее число слов в данном документе.

Обратная частота документа idf вычисляется по формуле

$$idf(t, D) = \log_2 \frac{|D|}{|\{d_i \in D \mid t \in d_i\}|}, \quad (3)$$

где $|D|$ – число документов в коллекции; $|\{d_i \in D \mid t \in d_i\}|$ – число документов из коллекции D , в которых встречается t (когда $n_t \neq 0$).

Затем полученный результат делится на произведение норм векторных представлений.

BLEU – это автоматическая метрика для оценки качества текста, сгенерированного системой машинного перевода или распознавания речи, путем сравнения с эталонными (референсными)

переводами, выполненными человеком. BLEU анализирует совпадения n -грамм (последовательностей из n слов) между кандидатом (текст, который оценивается) и одним или несколькими референсами. Обычно используются n -граммы от одной до четырех (униграммы, биграммы, триграммы, четырехграммы).

BLEU вычисляется по формуле

$$\text{BLEU} := BP \cdot e^{(\sum_{n=1}^{\infty} \omega_n \ln p_n)}, \quad (4)$$

где p_n – модифицированная точность n -грамм, BP – штраф за краткость, ω_n – положительные веса, в сумме дающие единицу (в базовой версии метрики $\omega_n = 1/N$, $n = 1, 2, \dots, N$). Модифицированная точность n -грамм рассчитывается по формуле

$$p_n := \frac{\sum_C \sum_{s \in C_n} \min(\text{Count}(s, C), \max_i(\text{Count}(s, R^{(i)})))}{\sum_C \sum_{s \in C_n} \text{Count}(s, C)}, \quad (5)$$

где Σ_c – суммирование по всем переводам-кандидатам C в текстовом корпусе; C_n – множество всех n -грамм, извлеченных из кандидата C ; s – конкретная n -грамма из множества C_n ; $\text{Count}(s, C)$ – количество вхождений s в C ; $\text{Count}(s, R^{(i)})$ – количество вхождений s в эталонный перевод $R^{(i)}$.

Штраф за краткость (brevity penalty) рассчитывается по формуле

$$BP = \begin{cases} 1, & c > r, \\ \exp(1 - \frac{r}{c}), & c \leq r, \end{cases} \quad (6)$$

где c – длина корпуса кандидата, r – длина корпуса референса.

Длина корпуса кандидата рассчитывается по формуле

$$c := \sum_C |C|, \quad (7)$$

где $|C|$ – количество слов в кандидате C .

Длина корпуса референса r , представляемая как сумма длин наиболее близких по длине эталонных строк, вычисляется по формуле

$$r := \sum_C \arg \min_i \| |C| - |R^{(i)}| \|, \quad (8)$$

где $|C|$ – количество слов в кандидате, $|R^{(i)}|$ – количество слов в i -м эталонном переводе.

Метрика BLEU позволяет объективно сравнивать качество автоматически сгенерированных текстов с эталонными, учитывая совпадения n -грамм и корректируя результат с помощью штрафа за краткость, чтобы избежать завышения оценки за слишком короткие ответы.

WRE – расстояние Левенштейна, нормированное по количеству слов. Расстояние Левенштейна – это метрика, измеряющая по модулю разность между двумя последовательностями символов [3]. Она определяется как минимальное количество односимвольных операций (например, вставки, удаления, замены), необходимых для превращения одной последовательности символов в другую.

На рис. 2 изображена архитектура state-of-the-art модели Whisper компании OpenAI, используемой как «начало» в предлагаемой информационной системе. Модель работает локально, без подключения к сети интернет, что решает проблему безопасности персональных данных пользователя [4].

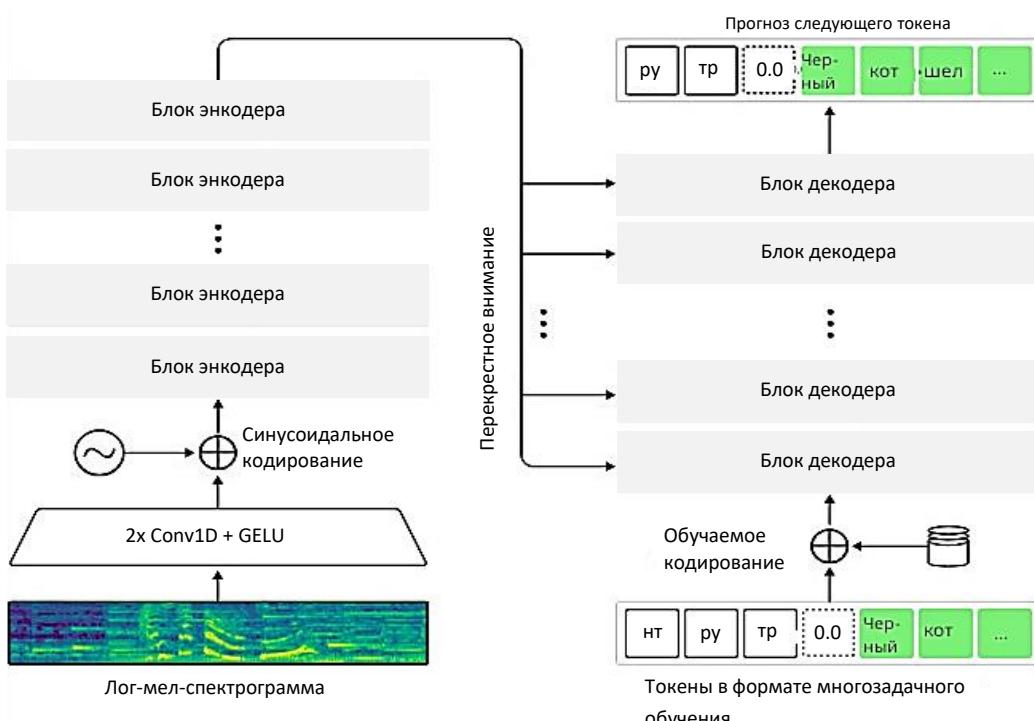


Рис. 2. Архитектура модели Whisper

Fig. 2. Whisper model architecture

Для оценки качества модели вышеперечисленные метрики рассчитываются на основании сравнения зачитанного в микрофон текста и текста, полученного после распознавания. Сравнительная характеристика разных моделей распознавания речи приведена в табл. 1.

Таблица 1

Сравнительная характеристика моделей распознавания речи

Table 1

Comparative characteristics of speech recognition models

Модель <i>Model</i>	Vram, Gb	Время распознавания четырехминутного текста <i>Recognition time for a four-minute text</i>	Cosine similarity	Word error rate	BLEU Score
vosk-model-small-ru-0.22	0,5	19 с 355 мс	0,6399	0,6050	0,1957
vosk-model-ru-0.42	2	2 мин 20 с	0,7560	0,4798	0,3699
whisper-tiny	1	10 с 938 мс	0,4813	0,8382	0,0404
whisper-base	1	11 с 481 мс	0,5564	0,7746	0,074
whisper-small	2	32 с 428 мс	0,6412	0,6570	0,144
whisper-medium	5	4 мин	0,7156	0,5145	0,364
whisper-large	10	4 мин	0,8303	0,499	0,3185
whisper-turbo	6	1 мин 58 с	0,7293	0,4566	0,4117

Наилучшим качеством транскрибации речи обладают модели whisper-large и whisper-turbo. Для реализации системы распознавания речи в данной работе выбрана модель whisper-turbo ввиду большей скорости обработки данных, позволяющей реализовывать потоковый режим работы системы, и меньших требований к вычислительной мощности машины. Затем полученный текстовый файл подается на вход модели переводчика, зачастую также основанной на вариациях трансформеров.

Результаты. На рис. 3 изображена архитектура модели T5 (Text-to-Text Transfer Transformer), выбранная как модель для обучения на большом корпусе текстов на английском, русском и китайском языках.

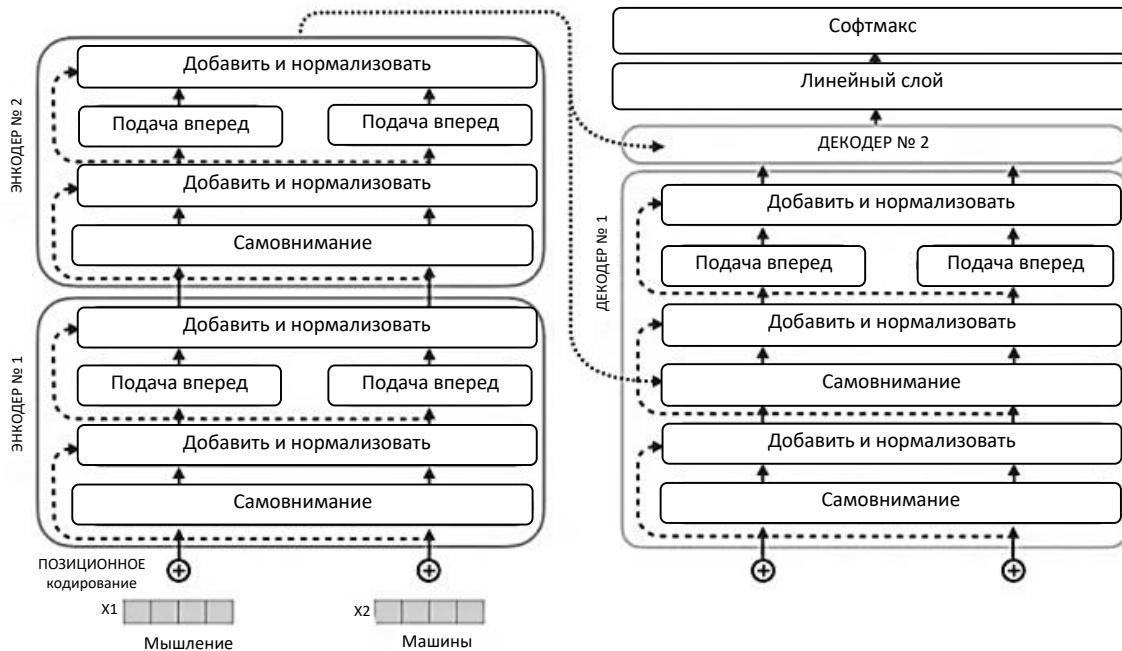


Рис. 3. Архитектура модели T 5
Fig. 3. Architecture of the T 5 model

Сравнительная характеристика разных моделей перевода приведена в табл. 2.

Таблица 2

Сравнительная характеристика моделей перевода

Table 2

Comparative characteristics of translation models

Модель <i>Model</i>	Нужен интернет <i>Need internet</i>	Vram, Gb	Время перевода <i>Translation time</i>	Cosine similarity	Word error rate	BLEU Score
utrobinmv/utrobinmv/t5_translate_en_ru_zh_small_1024	Нет	<3	24 с 583 мс	0,7185	0,5892	0,215
utrobinmv/t5_translate_en_ru_zh_large_1024	Нет	3	49 с 629 мс	0,6951	0,529	0,2387
utrobinmv/t5_translate_en_ru_zh_large_1024_v2	Нет	>4	1 мин	0,6312	0,6618	0,1723
google translate	Да	<1	0 с	0,7798	0,3714	0,4056
Яндекс переводчик	Да	<1	0 с	0,7295	0,5539	0,2925

Необходимость подключения к сети интернет для осуществления перевода создает угрозу безопасности. В табл. 2 добавлены для сравнения метрики качества перевода моделей с открытым кодом и коммерческих сервисов. Для описываемой интеллектуальной системы была выбрана модель utrobinmv/t5_translate_en_ru_zh_large_1024, имеющая следующие значения качества:

Cosine Similarity: 0,6951,
word error rate: 0,529,
BLEU Score: 0,23 879 138 591 567 485.

Метрики качества перевода распознанного текста с русского языка на китайский и обратно:

Cosine Similarity: 0,4232,
word error rate: 0,8233,
BLEU Score: 0,07 639 410 899 117 652.

Видно, что данные результаты далеки от желаемых. Для улучшения качества перевода после проведения ряда исследований и тестов было решено использовать английский язык как промежуточный для получения более качественного перевода, поскольку результаты оценки качества прямого перевода с английского на русский и с китайского на английский выше, чем прямого перевода с русского на китайский.

Метрики качества перевода распознанного текста с русского языка на английский, затем на китайский, затем обратно на английский и потом на русский представлены ниже:

Cosine Similarity: 0,5571,
word error rate: 0,7484,
BLEU Score: 0,0 954 180 649 678 097.

Анализируя полученные результаты по метрикам, можно отметить, что при переводе на китайский язык улучшение результата происходит при использовании промежуточного перевода на английский язык и далее – на русский как при прямом, так и обратном проходе.

Метрики качества интеллектуальной системы в приложении к английскому языку:

Cosine Similarity: 0,4107,
word error rate: 0,8786,
BLEU Score: 0,07 190 972 701 489 706.

Метрики качества интеллектуальной системы в приложении к китайскому языку:

Cosine Similarity: 0,5470,
word error rate: 0,7977,
BLEU Score: 0,1 076 237 727 294 554.

Достоинством описанной архитектуры системы является простота замены отдельных модулей, что позволяет проверять множество вариантов агентов без изменения общей архитектуры для проведения сравнительного анализа при поиске оптимального решения.

В противовес описанной каскадной архитектуре, состоящей из блоков транскрибации аудио- и машинного перевода текста, можно поставить прямые модели, где одна нейросетевая модель сразу преобразует аудиосигнал в перевод без промежуточного текстового представления на исходном языке. Сравнение данных методов представлено в работе Apple, где авторы показали, что даже при близких BLEU-оценках согласованность между транскриптом и переводом у каскадных систем выше, чем у монолитных моделей. Данный подход может улучшать качество перевода, но зачастую снижает точность транскрипта [5]. Аналогичную картину описали исследователи из Vicomtech: в их эксперименте пользователи отдали предпочтение каскадной схеме в 42 % случаев против 17 % за прямую схему, несмотря на сопоставимый уровень автоматических метрик [6]. В описываемом случае перевода с русского языка на китайский проблемой является малое количество параллельных корпусов, содержащих русскоязычные аудиоданные и соответствующие китайские текстовые транскрипции. Она усугубляется значительными типологическими различиями между русским и китайским языками, относящимися к разным лингвистическим семьям.

Тестирование показало, что для русско-английского перевода система достигает значений Cosine Similarity 0,695, WER 0,529 и BLEU Score 0,239.

Заключение. Система распознавания речи в своем настоящем виде может решать поставленную задачу с удовлетворительным для описанной проблемы качеством без рисков несанкционированного доступа к данным, поскольку работает без подключения к сети интернет. При использовании каскадного перевода через английский язык качество русско-китайского перевода улучшается на 32 % по метрике Cosine Similarity (с 0,423 до 0,557) и на 25 % по метрике BLEU Score (с 0,076 до 0,095). Предложенная информационная система может быть внедрена в образовательный процесс вне зависимости от учебной дисциплины. При некоторых доработках агенты распознавания речи и перевода текста смогут оперировать любыми доменными терминами и аббревиатурами, что позволит устранить необходимость изучения преподавателем языка иностранных граждан и (или) изучения иностранными гражданами языка, доступного для преподавателя. Кроме сферы образования предложенная интеллектуальная система может быть применена на выставках, конференциях, международных форумах. Возможен параллельный перевод на различные языки, что позволяет участникам международных форумов активно участвовать во всех мероприятиях.

Модель для перевода работает локально, переобучать ее нецелесообразно, но в будущем существует возможность дообучения на лекционных материалах для повышения точности перевода доменных терминов и аббревиатур. Возможна замена модели автоматического распознавания речи на модель, дообученную на доменной лексике, для увеличения точности транслитерации и перевода терминов, а также аббревиатур, которые часто встречаются в лекционных материалах и на которых модель общего назначения компании OpenAI не обучалась [7]. В дальнейшем планируется реализовать потоковую обработку речи, упростить развертывание системы, дообучить транскрибирующую агента и агента для перевода на доменной лексике.

Вклад авторов. В. А. Чуйко разработал концепцию работы, провел ряд исследований, критический анализ модели и текста статьи. Л. П. Кузьменков осуществил разработку системы, провел исследования и написал текст статьи. Е. И. Козлова провела критический анализ содержания статьи и подготовила окончательный вариант работы для публикации.

References

1. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., ..., Polosukhin I. *Attention Is All You Need*, 2017. Available at: <https://arxiv.org/abs/1706.03762> (accessed 12.05.2025).
2. Papineni K., Roukos S., Ward T., Zhu W.-J. BLEU: a method for automatic evaluation of machine translation. *40th Annual Meeting of the Association for Computational Linguistics (ACL)*, Philadelphia, July 2002, pp. 311–318.
3. Tzoukermann E., Miller C. Evaluating automatic speech recognition in translation. *Proceedings of the 13th Conference of the Association for Machine Translation in the Americas*, Boston, MA, March 2018, vol. 2: MT Users' Track, pp. 294–302.
4. Sperber M., Setiawan H., Gollan C., Nallasamy U., Paulik M. Consistent transcription and translation of speech. *Transactions of the Association for Computational Linguistics (TACL)*, 2020, vol. 8, pp. 695–709.
5. Etchegoyhen T., Arzelus H., Gete H., Alvarez A., Torre I. G., ..., Fernandez E. B. Cascade or direct speech translation? A case study. *Applied Sciences*, 2022, vol. 12, iss. 3, pp. 1097.
6. Radford A., Kim J. W., Xu T., Brockman G., McLeavey C., Sutskever I. *Robust Speech Recognition via Large-Scale Weak Supervision*, 2022. Available at: <https://arxiv.org/abs/2212.04356> (accessed 12.05.2025).
7. Kumar L. A., Renuka D. K., Chakravarthi B. R., Mandl T. *Automatic Speech Recognition and Translation for Low Resource Languages*. Wiley-Scrivener, 2024, 496 p.

Информация об авторах

Кузьменков Леонид Павлович, студент, Белорусский государственный университет.
E-mail: salamandrdragrs@yandex.ru

Чуйко Владислав Александрович, магистр физико-математических наук, старший преподаватель, Белорусский государственный университет.
E-mail: Vchuyko@bsu.by

Козлова Елена Ивановна, кандидат физико-математических наук, доцент, Белорусский государственный университет.
E-mail: kozlova@bsu.by

Information about the authors

Leonid P. Kuzmenkov, Student, Belarusian State University.
E-mail: salamandrdragrs@yandex.ru

Vladislav A. Chuyko, M. Sc. (Phys.-Math.), Senior Lecturer, Belarusian State University.
E-mail: Vchuyko@bsu.by

Alena I. Kazlova, Ph. D. (Phys.-Math.), Assoc. Prof., Belarusian State University.
E-mail: kozlova@bsu.by



УДК 004.048
DOI: 10.37661/1816-0301-2025-22-3-35-44

Оригинальная статья
Original Article

Извлечение и анализ микрореакций в задаче нейросетевого распознавания лжи по видеозображению лица

К. А. Котова[✉], В. С. Садов

Белорусский государственный университет,
пр. Независимости, 4, Минск, 220030, Беларусь
[✉]E-mail: ksyu.kotova.79@gmail.com

Аннотация

Цели. Целями исследования являются сбор данных, разработка алгоритма автоматического извлечения микрореакций из видеозаписей, а также формирование правил комбинаций двигательных единиц, на основе которых определяются базовые эмоции человека.

Методы. Микрореакции лица человека – это короткая непроизвольная реакция, которая может появляться при попытке человека скрыть его истинные эмоции. При решении задачи распознавания лжи микрореакции играют ключевую роль и служат важным индикатором сокрытия правдивой информации. В статье для анализа мимики из системы кодирования лицевых движений (Facial Action Coding System, FACS) использовались двигательные единицы (Action Units, AUs), полученные с помощью библиотеки ru-feat.

Результаты. Собран набор данных, состоящий из видеозаписей группы конкретных людей. Разработаны правила на основе комбинаций двигательных единиц и их интенсивностей для определения базовых эмоций, а также сформулирован алгоритм определения и извлечения микрореакций из видеозаписей. Результат исследования алгоритма показал отрицательную корреляцию эмоции радости с фактом проявления лжи.

Заключение. Полученные результаты позволяют расширить информационный базис при нейросетевом распознавании лжи по видеоряду с изображениями лица за счет детектирования и анализа на них микрореакций.

Ключевые слова: базовые эмоции, извлечение микрореакций, python-библиотека ru-feat, двигательные единицы, система кодирования лицевых движений, эмоциональное состояние, вариативность комбинаций

Для цитирования. Котова, К. А. Извлечение и анализ микрореакций в задаче нейросетевого распознавания лжи по видеозображению лица / К. А. Котова, В. С. Садов // Информатика. – 2025. – Т. 22, № 3. – С. 35–44. – DOI: 10.37661/1816-0301-2025-22-3-35-44.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 08.08.2025
Подписана в печать | Accepted 22.08.2025
Опубликована | Published 30.09.2025

Extracting and analysing micro-expressions in a neural network lie detection task

Ksenia A. Kotova[✉], Vasiliy S. Sadov

*Belarusian State University,
av. Nezavisimosti, 4, Minsk, 220030, Belarus
✉E-mail: ksyu.kotova.79@gmail.com*

Abstract

Objectives. The objectives of the study are to collect data, develop an algorithm for automatic extraction of microexpressions from video recordings, and form rules for combinations of motor units, based on which basic human emotions are determined.

Methods. Human facial microexpressions are brief, involuntary reactions that may appear when a person attempts to hide their true emotions. Microexpressions play a key role in lie detection and are an important indicator of the concealment of truthful information. In this article, Action Units (movement units) obtained using the py-feat library from the Facial Action Coding System (FACS) were used to analyse facial expressions.

Results. A dataset consisting of video recordings of a group of specific people was collected. Rules were developed based on combinations of action units and their intensities to determine basic emotions. An algorithm for determining and extracting microexpressions from video recordings was also formulated. The results of the algorithm study showed a negative correlation between the emotion of joy and the manifestation of lying.

Conclusion. The results obtained allow us to expand the information base for neural network lie detection using a video series of facial images by detecting and analysing microexpressions on them.

Keywords: basic emotions, micro-expression extraction, python library py-feat, Action Units (AUs), Facial Action Coding System (FACS), emotional state, variability of combinations

For citation. Kotova K. A., Sadov V. S. *Extracting and analysing micro-expressions in a neural network lie detection task*. Informatika [Informatics], 2025, vol. 22, no. 3, pp. 35–44 (In Russ.). DOI: 10.37661/1816-0301-2025-22-3-35-44.

Conflict of interest. The authors declare of no conflict of interest.

Введение. Распознавание лжи относится к следственным методам, которые используются для определения правдивости и надежности сказанного. В основном это осуществляется путем рассмотрения определенных поведенческих и физиологических признаков, а также более широкой контекстуальной и ситуационной информации.

Не существует ни одного однозначного признака обмана. Ни одно мышечное подергивание, ни одно выражение лица или жест не доказывают с абсолютной уверенностью, что человек лжет. Поэтому большинство современных методов обнаружения обмана в значительной степени опираются на разнообразные способы сбора, анализа и интерпретации эмоциональных и физиологических данных.

Важнейший аспект в выявлении обмана – установление так называемой «базовой линии» поведения, которое считается «нормальным» для конкретного человека. Основной процесс распознавания лжи заключается в поиске признаков, указывающих на изменения или отклонения от этой базовой линии. Такие признаки могут проявляться через «горячие точки» в различных наблюдаемых каналах: микророждениях, языке тела, голосе, манере речи и содержании высказываний.

При обмане лицо часто передает два сообщения одновременно – то, что лжец хочет показать, и то, что он стремится скрыть. Скрытые эмоции могут непроизвольно проявляться в виде микророждений – кратких (длительностью не более 0,5 с [1]) непроизвольных мимических реакций, раскрывающих истинные чувства.

Согласно П. Экману [1], единичное микророждение или кратковременная «утечка» эмоционального сигнала не могут рассматриваться в качестве достаточного индикатора для определения лжи. Тем не менее микророждения представляют собой один из наиболее информативных неверbalных маркеров, позволяющих повысить вероятность выявления обмана.

Эмоциональные выражения могут быть как намеренно искажены, так и использованы для маскировки иных эмоциональных состояний. Исследования демонстрируют [2], что для большинства поддельных выражений характерна асимметрия, в то время как искренние выражения в большинстве случаев симметричны (за исключением отдельных состояний).

При страхе или грусти одним из признаков фальсификации эмоций является отсутствие характерных движений лба [2]. В случае с выражением радости ключевой признак неискренности – отсутствие активности глазных мышц во время улыбки. Неподвижность наружной части круговой мышцы глаза (*orbicularis oculi pars lateralis*, или AU6 по системе FACS [4]) отличает фальшивую улыбку от подлинной. Данный признак нередко остается незамеченным, что обуславливает высокую восприимчивость собеседников к фальсифицированным улыбкам и их широкое использование в качестве эмоциональной «маски».

Одна из проблем микровыражений – это короткая длительность, что делает их трудноуловимыми невооруженным глазом. Поэтому для оптимизации подхода к распознаванию лжи требуется автоматизировать извлечение и анализ микровыражений из видеозаписей.

Цель данной работы заключается в разработке и тестировании алгоритма извлечения микровыражений, одним из этапов которого является формирование правил – комбинаций двигательных единиц, определяющих базовые эмоции: радость, грусть, страх, отвращение, злость, удивление.

Система FACS. Наиболее признанным и достоверным инструментом для измерения визуально различимых движений лица является система кодирования лицевых движений (Facial Action Coding System, FACS). Она была разработана психологами Полом Экманом и Уоллесом В. Фризеном с целью объективного измерения мимических выражений в исследованиях поведения человека [4].

Методика FACS имеет анатомическую основу и включает 44 различные двигательные единицы AUs, каждая из которых соответствует определенному движению лица. Дополнительно учитываются наборы движений и положений головы и глаз. Каждая двигательная единица имеет цифровой код (AUxx), позволяющий идентифицировать отдельную мышцу или группы мышц, которые сокращаются или расслабляются, вызывая наблюдаемые изменения внешнего вида. Это обеспечивает возможность анализа мельчайших мимических движений. Интенсивность каждой двигательной единицы оценивается от нуля до единицы, где единица – максимальная интенсивность. Под «событием» (event) понимается единичное мимическое выражение, которое может быть закодировано в полном объеме путем разложения его на набор AU, включающий как одну, так и комбинацию нескольких единиц.

В табл. 1 описаны двигательные единицы, использующиеся в исследовании.

Таблица 1
 Двигательные единицы, использующиеся библиотекой py-feat

Table 1
Action Units, used by the py-feat library

Номер двигательной единицы <i>Action unit number</i>	Оригинальное название <i>Original title</i>	Мышечная основа <i>Muscular base</i>
AU01	Inner Brow Raiser	Поднятие лобной мышцы (медиальная часть)
AU02	Outer brow raiser	Поднятие лобной мышцы (латеральная часть)
AU04	Brow lowerer	Мышца, опускающая бровь
AU05	Upper lid raiser	Мышца, поднимающая верхнее веко
AU06	Cheek raiser	Круговая мышца глаза (глазничная часть)
AU07	Lid tightener	Круговая мышца глаза (вековая часть)
AU09	Nose wrinkler	Мышца, поднимающая верхнюю губу и крыло носа
AU10	Upper lip raiser	Мышца, поднимающая верхнюю губу
AU11	Nasolabial deepener	Малая скуловая мышца
AU12	Lip corner puller	Большая скуловая мышца
AU14	Dimpler	Щечная мышца
AU15	Lip corner depressor	Мышца, опускающая угол рта
AU17	Chin raiser	Подбородочная мышца
AU20	Lip stretcher	Мышца смеха
AU23	Lip tightener	Круговая мышца рта

Окончание табл. 1

End of table. 1

Номер двигательной единицы <i>Action unit number</i>	Оригинальное название <i>Original title</i>	Мышечная основа <i>Muscular base</i>
AU24	Lip pressor	Круговая мышца рта
AU25	Lips part	Мышца, опускающая нижнюю губу
AU26	Jaw drop	Жевательная мышца
AU28	Lip suck	Круговая мышца рта
AU43	Eyes closed	Расслабление мышцы, поднимающей верхнее веко

Библиотека ry-feat представляет собой набор инструментов и моделей для распознавания выражений лица (включая двигательные единицы, эмоции и ключевые точки лица) на изображениях и видеозаписях [6]. Она позволяет обрабатывать и анализировать данные о выражениях лица, а также визуализировать ключевые точки лица по ним. Библиотека является бесплатной, простой в использовании и с открытым исходным кодом, что позволяет удобно работать с данными о мимике.

Основные возможности ry-feat: детектирование лица, определение его ключевых точек, оценка положения лица и головы, определение двигательных единиц и эмоций. Каждый из этих инструментов является отдельной моделью, которая обучалась и оценивалась на следующих наборах данных: WIDER (детектирование лица), 300W (ключевые точки), BIWI Kinect (положение головы), DIFSA + (двигательные единицы), Namba (двигательные единицы), AffectNet (эмоции) [7]. В библиотеке ry-feat при классификации двигательных единиц заложены модель Feat-XGB, основанная на методе машинного обучения XGboost, возвращающая непрерывную оценку активности AU (значения 0–1), и модель Feat-SVM, основанная на модели LinearSVC, которая выдает бинарные метки (активно/не активно).

Методология исследования.

Сбор данных. Для решения задачи извлечения микровыражений из видеозаписей был собран набор данных [8], состоящий из видеоинтервью с группой людей, которые предварительно дали свое согласие на участие в исследовании.

С испытуемыми было заранее оговорено, что на вопросы интервью необходимо отвечать правдиво или лживо по их усмотрению и что ответы испытуемых могут быть как односложными, так и подробными. Часть испытуемых вручную разметили видеозаписи, указав на свои ложные и правдивые ответы. Пример, поясняющий принцип представления сформированного набора данных, приведен в табл. 2. Для испытуемого 1 были записаны два набора данных видеозаписей с разным разрешением и частотой кадров в секунду для исследования влияния параметров видео на точность классификации двигательных единиц.

Таблица 2

Пример, описывающий собранные видеозаписи, по нескольким испытуемым

Table 2

An example describing the collected video recordings for several test subjects

Номер испытуемого <i>Subject number</i>	Метка <i>Label</i>	Количество видео <i>Number of videos</i>	Расширение видео <i>Video expansion</i>	Частота кадров в секунду <i>Frame rate per second</i>
1	Ложь	12	1440×1080	25
	Правда	10		
	Ложь	14	1920×1080	30
	Правда	19		
2	Ложь	9	1920×1080	30
	Правда	17		
3	Не размечены	41	1920×1080	30

Классификация видеоданных с использованием ru-feat. К каждому видео был применен классификатор ru-feat и сформированы CSV-файлы, в которых для всех кадров описаны значения положения головы по осям X и Y и значения двигательных единиц из табл. 1.

Формирование комбинаций AU для определения эмоций. В табл. 3 в системе FACS предложены комбинации двигательных единиц, определяющих базовые эмоции [4].

Таблица 3

Комбинации двигательных единиц, определяющих эмоции, по системе FACS

Table 3

Combinations of Action Units that determine emotions, according to the FACS system

Эмоция Emotion	Комбинация Combination
Радость	$AU6 + AU12$
Грусть	$AU1 + AU4 + AU15$
Удивление	$AU1 + AU2 + AU5 + AU26$
Страх	$AU1 + AU2 + AU4 + AU5 + AU7 + AU20 + AU26$
Злость	$AU4 + AU5 + AU7 + AU23$
Отвращение	$AU9 + AU15 + AU16$

Между тем такой подход не учитывает особенности выражения эмоций отдельного человека и их интенсивность. Adrian K. Davison и др. [9] предложили иной подход к классификации эмоций по комбинациям двигательных единиц. Исследователи учили, что отдельная двигательная единица вне комбинации может относиться к некоторой базовой эмоции, а также они учили вариативность комбинаций. На основании их исследования и анализа собранных данных в табл. 4 авторами предложены правила комбинации двигательных единиц, определяющих эмоции и микровыражения.

Таблица 4

Комбинации двигательных единиц для определения микровыражений

Table 4

Combinations of the Action Units for microexpressions determining

Эмоция Emotion	Комбинации Combinations	Пояснение Explanation
Радость	$AU12$	Улыбка без участия глаз
	$AU6 + AU12$	Естественная улыбка
	$AU6 + AU12 + AU25$	Улыбка с приоткрытым ртом
Грусть	$AU1 + AU15$	Поднятые внутренние брови, уголки рта вниз
	$AU1 + AU15 + AU17$	Добавлен приподнятый подбородок
	$AU1 + AU17$	Поднятые брови, приподнятый подбородок
Злость	$AU4 + AU7 + AU23$	Опущенные брови, напряженные веки, сжатые губы
	$AU4 + AU7 + AU24$	Опущенные брови, напряженные веки, втянутые губы
	$AU4 + AU5 + AU23$	Опущенные брови, широко открытые глаза, сжатые губы
	$AU4 + AU7 + AU9 + AU23$	Опущенные брови, напряженные веки, сморщеный нос, сжатые губы
Удивление	$AU1 + AU5 + AU26$	Поднятые брови, широко открытые глаза, растянутые губы
	$AU2 + AU5 + AU26$	Внешние брови выше, широко открытые глаза, открытый рот
	$AU1 + AU2 + AU5 + AU26$	Обе части бровей подняты, широко открытые глаза, открытый рот
Страх	$AU1 + AU5 + AU20 + AU26$	Поднятые брови, широко открытые глаза, растянутые губы, открытый рот
	$AU2 + AU5 + AU20 + AU26$	Поднятые внешние брови, широко открытые глаза, растянутые губы, открытый рот
	$AU1 + AU5 + AU26$	Поднятые брови, широко открытые глаза, открытый рот
Отвращение	$AU9 + AU15$	Сморщеный нос, уголки рта вниз
	$AU9 + AU17$	Сморщеный нос, приподнятый подбородок

Определение эмоций по комбинациям AU. Из анализа были исключены кадры с высоким уровнем интенсивности ($>0,6$) двигательной единицы AU43, описывающей закрытые глаза, так как эта двигательная единица вызывает большую погрешность в определении эмоций другими комбинациями.

Далее для каждого кадра определяется активная эмоция по комбинациям двигательных единиц. Если активна хотя бы одна из заданных комбинаций AU и при этом все входящие в нее единицы имеют интенсивность выше порога 0,6, то такие комбинации считаются активными. Данный параметр определен экспериментально.

Затем вычисляется средняя интенсивность для активных комбинаций и выбирается комбинация с максимальным значением средней интенсивности двигательных единиц в комбинации. Вычисления проводятся по формуле

$$I = \max \left(\frac{1}{n} \times \sum_{i=1}^n AU_i \right) \times 100,$$

где I – максимальная интенсивность комбинации двигательных единиц (%), n – количество двигательных единиц в комбинации, AU_i – значение i -го AU.

Таким образом, по правилам табл. 4 определяется эмоция. Если ни одна эмоция не активна, то кадр помечается как нейтральный.

Детектирование микровыражений. Для детектирования микровыражений определяются последовательности кадров с одинаковой доминирующей эмоцией, длительность которой не превышает 12–15 кадров (для 25–30 FPS соответственно), т. е. не более 0,5 с, что является характерной длительностью микровыражений.

Для каждой такой последовательности фиксируются: начальный кадр, тип эмоции, комбинация AU, определяющая эмоцию, средняя интенсивность, длительность в кадрах, метка ложь/правда. Для того чтобы зафиксировать последовательность как микровыражение, было принято, что средняя интенсивность эмоции должна составлять не менее 65 %. Этот параметр установлен экспериментально исходя из того, что микровыражение – кратковременный и яркий эмоциональный всплеск.

Блок-схема разработанного алгоритма детектирования и извлечения микровыражений с использованием видеоряда изображений лица показана на рис. 1.

Алгоритм состоит из следующих шагов:

- составление набора данных, включающего группы из людей видеointервью;
- вычисление двигательных единиц, определяющих положения головы, по всем видеозаписям с использованием библиотеки ry-feat;
- формирование CSV-файлов с результатами классификации кадров видеоряда детекторами библиотеки ry-feat;
- загрузка, обработка и анализ файлов;

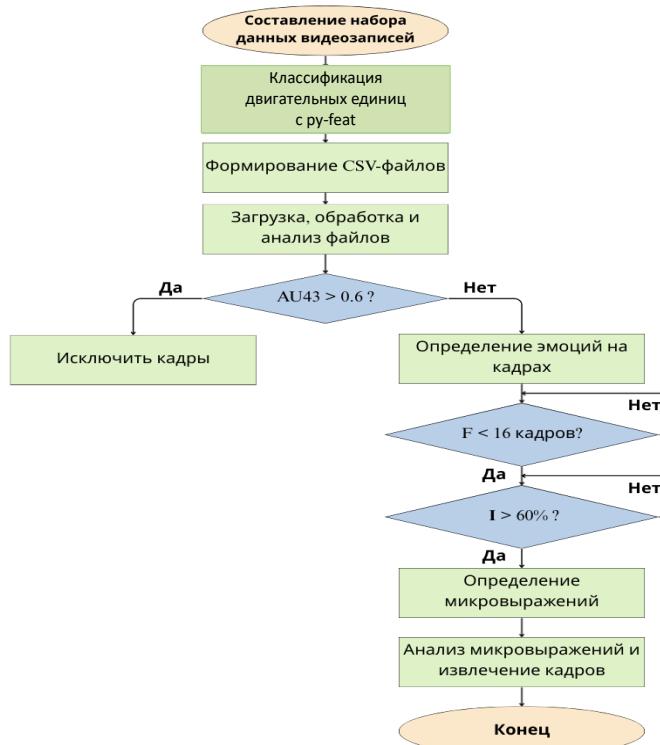


Рис. 1. Блок-схема алгоритма детектирования и извлечения микровыражений (F – длительность эмоций, I – интенсивность эмоций)

Fig. 1. Flow Chart of the algorithm for detecting and extracting microexpressions (F – duration of emotions, I – intensity of emotions)

- исключение кадров, у которых интенсивность двигательной единицы AU43, описывающей закрытые глаза, выше порога в 0,6;
- определение эмоций на основе активных комбинаций двигательных единиц по сформированным правилам;
- определение кратковременных эмоций, длительность которых не превышает 12–15 кадров, т. е. не более 0,5 с;
- определение активных эмоций, т. е. эмоций с интенсивностью не менее 60 %;
- анализ микровыражений и извлечение из видео соответствующих кадров.

Результаты исследования. В процессе исследования были извлечены микровыражения из видеоряда каждого из испытуемых. Пример итоговой статистики по микровыражениям для нескольких испытуемых приведен в табл. 5.

Таблица 5

Количество микровыражений в результате их извлечения из видеointервью для нескольких испытуемых

Table 5

Number of microexpressions extracted from videointerviews for several subjects

Номер испытуемого <i>Subject number</i>	Количество кадров <i>Number of frames</i>	Метка <i>Label</i>	Количество микровыражений по метке <i>Number of microexpressions by label</i>	Доминирующая эмоция микровыражений <i>Dominant emotion of microexpressions</i>
1	4464	Ложь	553	Удивление
		Правда	293	
	9518	Ложь	79	Грусть
		Правда	78	
2	8707	Ложь	185	Грусть
		Правда	241	
3	8270	Не размечено	173	Грусть

В результате анализа корреляции метки и полученных интенсивностей эмоций было выявлено, что эмоция радости имеет отрицательную корреляцию с меткой для размеченных наборов данных, а грусть и злость также в этих случаях имеют положительную корреляцию с меткой. Это означает, что испытуемым несвойственно испытывать эмоцию радости во время обмана в отличие от эмоций грусти и злости.

На рис. 2 изображен график корреляции интенсивностей полученных эмоций с метками для испытуемого 1.

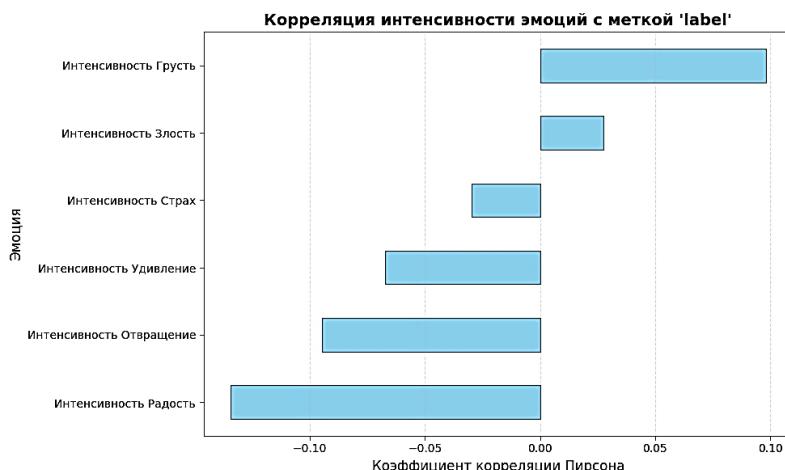


Рис. 2. Корреляция полученных интенсивностей эмоций с меткой ложь/правда для испытуемого 1

Fig. 2. Correlation of the obtained emotion intensities with the lie/truth label for test subject 1

На рис. 3 продемонстрированы микровыражения при лжи испытуемого 1 к каждой базовой эмоции: Anger – злость, Disgust – отвращение, Fear – страх, Happiness – радость, Sadness – грусть, Surprise – удивление.

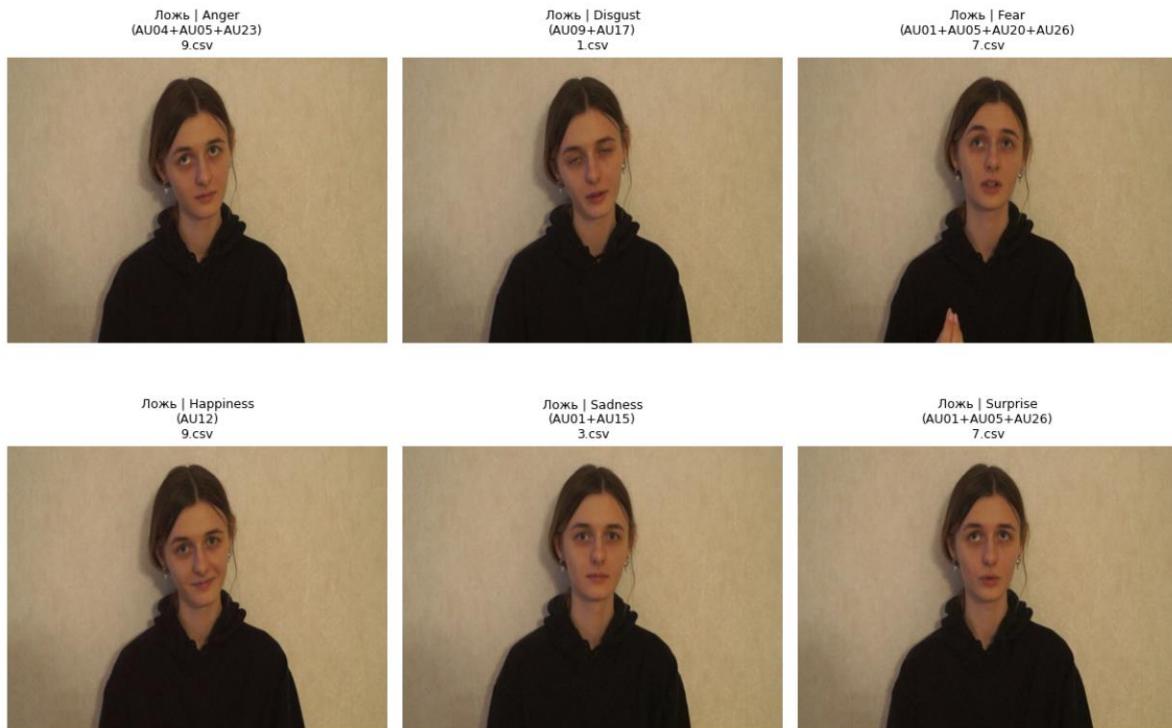


Рис. 3. Микровыражения испытуемого 1 из первого интервью при лжи

Fig. 3. Microexpressions of subject 1 from the first interview while lying

Заключение. В результате исследования был собран набор данных, состоящий из видеointервью группы различных людей, и разработан алгоритм автоматического извлечения микровыражений из видеозаписей на основе двигательных единиц AU, описывающих движения лицевых мышц. Были проанализированы комбинации двигательных единиц из системы FACS для получения эмоций, и на основе предположения о том, что у различных людей эмоции могут иметь различные комбинации двигательных единиц, были сформированы уточненные правила их комбинаций.

Применение полученной матрицы комбинаций двигательных единиц позволило более достоверно классифицировать базовые эмоции на анализируемых видеокадрах: точность классификации составила 57 % при использовании предложенного подхода против 3 % при применении базовой матрицы из системы FACS.

Проведенный анализ микровыражений, полученных с помощью разработанного алгоритма, позволил установить, что эмоция радости коррелирует с меткой правды в наборах данных, а эмоции грусти и злости коррелируют с меткой лжи.

Было выявлено, что на видео, где люди лгут, содержится больше микровыражений, чем на видео, где говорят правду. При этом интенсивность проявления таких эмоций, как радость, грусть, злость и страх, выше, чем у правдивых микровыражений, что может быть связано с попытками скрыть истинную эмоцию либо со страхом разоблачения. Однако стоит учитывать, что проявление эмоций зависит от физиологии человека и его мимических особенностей. Это усложняет задачу классификации и может потребовать дополнительную информацию от других источников.

Предложенный алгоритм автоматизированного извлечения микровыражений может быть использован в задаче нейросетевого распознавания лжи в контексте с видео- и аудиоинформацией в ходе коммуникационного процесса.

Необходимо отметить, что для реализации всех преимуществ предложенной технологии распознавания лжи требуется достаточно высокое качество видеозаписей и одновременно повышенные вычислительные ресурсы, так как, в противном случае, высококачественные видеозаписи длительностью дольше 60 с могут не классифицироваться библиотекой py-feat.

Вклад авторов. *K. A. Котова* – проведение экспериментальных исследований, разработка алгоритма, написание текста статьи; *B. C. Садов* – постановка целей и задач статьи, обсуждение результатов, корректировка текста статьи.

Список использованных источников

1. Экман, П. Психология лжи. Обмани меня, если сможешь / П. Экман ; пер. с англ. – СПб. : Питер, 2021. – 384 с.
2. Экман, П. Узнай лжеца по выражению лица / П. Экман ; пер. с англ. – СПб. : Питер, 2019. – 272 с.
3. Экман, П. Психология эмоций. Я знаю, что ты чувствуешь / П. Экман ; пер. с англ. – СПб. : Питер, 2014. – 336 с.
4. Ekman, P. What the Face Reveals: Basic and Applied Studies of Spontaneous Expression Using the Facial Action Coding System (FACS) / P. Ekman, E. L. Rosenberg. – N. Y. : Oxford University Press, 2005. – 662 p.
5. Facial Action Coding System (FACS). – United Kingdom, 2025. – URL: <https://www.eiagroup.com/resources/facial-expressions/facs-explained/> (date of access: 01.08.2025).
6. Py-Feat: Python Facial Expression Analysis Toolbox. – Germany, 2022–2025. – URL: <https://py-feat.org/pages/intro.html> (date of access: 08.08.2025).
7. Py-Feat: Python Facial Expression Analysis Toolbox / J. H. Cheong, T. Xie, S. Byrne, L. J. Chang. – Germany : Dartmouth College, 2021. – URL: https://www.researchgate.net/publication/350749851_Py-Feat_Python_Facial_Expression_Analysis_Toolbox (date of access: 01.08.2025).
8. Котова, К. А. Формирование набора данных для обучения метода случайных лесов в задачах распознавания лжи по мимике лица / К. А. Котова // Интеллектуальные, сенсорные и мехатронные системы-2025 : сб. науч. тр. (по материалам студенческих науч.-техн. конф.) / Белорус. нац. техн. ун-т ; редкол.: А. В. Стаселович, Е. А. Богданова ; сост.: С. А. Рыбчак, Е. А. Богданова, П. С. Колесников. – Минск : БНТУ, 2025. – С. 70–74.
9. Davison, A. K. Objective classes for micro-facial expression recognition / A. K. Davison, W. Merghani, M. H. Yap // Journal of Imaging. – 2018. – Vol. 4, no. 10. – URL: <https://www.mdpi.com/2313-433X/4/10/119> (date of access: 01.08.2025).

References

1. Ekman P. *Telling Lies: Clues to Deceit in the Marketplace, Politics, and Marriage*. New York, W. W. Norton & Company, 1985, 368 p.
2. Ekman P. *Unmasking the Face: A Guide to Recognizing Emotions From Facial Expressions*. Los Altos, CA, Malor Books, 2003, 212 p.
3. Ekman P. *Emotions Revealed: Understanding Faces and Feelings*. Phoenix, Nairobi, Kenyan, 2004, 336 p.
4. Ekman P., Rosenberg E. L. *What the Face Reveals: Basic and Applied Studies of Spontaneous Expression Using the Facial Action Coding System (FACS)*. New York, Oxford University Press, 2005. – 662 p.
5. Facial Action Coding System (FACS). United Kingdom, 2025. Available at: <https://www.eiagroup.com/resources/facial-expressions/facs-explained/> (accessed 01.08.2025).
6. Py-Feat: Python Facial Expression Analysis Toolbox. Germany, 2022–2025. Available at: <https://py-feat.org/pages/intro.html> (accessed 08.08.2025).
7. Cheong J. H., Xie T., Byrne S., Chang L. J. *Py-Feat: Python Facial Expression Analysis Toolbox*. Germany, Dartmouth College, 2021. Available at: https://www.researchgate.net/publication/350749851_Py-Feat_Python_Facial_Expression_Analysis_Toolbox (accessed 01.08.2025).
8. Kotova K. A. *Formation of a dataset for training the random forest method in tasks of lie detection based on facial expressions*. Intellektual'nye, sensornye i mehatronnye sistemy-2025 : sbornik nauchnyh trudov (po materialam studencheskikh nauchno-tehnicheskikh konferencij) [Intelligent, Sensory and Mechatronic Systems-

2025: *Collection of Scientific Papers (Based on Materials from Student Scientific and Technical Conferences)*]. Ed. board: A. V. Staselovich, E. A. Bogdanova ; compiled by S. A. Rybchak, E. A. Bogdanova, P. S. Kolesnikov. Minsk, Belorusskij naciona'l'nyj tehnicheskij universitet, 2025, pp. 70–74 (In Russ.).

9. Davison A. K., Merghani W., Yap M. H. Objective classes for micro-facial expression recognition. *Journal of Imaging*, 2018, vol. 4, no. 10. Available at: <https://www.mdpi.com/2313-433X/4/10/119> (accessed 01.08.2025).

Информация об авторах

Котова Ксения Андреевна, магистрант, Белорусский государственный университет, факультет радиофизики и компьютерных технологий.
E-mail: ksyu.kotova.79@gmail.com

Садов Василий Сергеевич, кандидат технических наук, доцент, профессор кафедры интеллектуальных систем факультета радиофизики и компьютерных технологий, Белорусский государственный университет.
E-mail: sadov@bsu.by

Information about the authors

Ksenia A. Kotova, Undergraduate of Belarusian State University, Faculty of Radiophysics and Computer Technologies.
E-mail: ksyu.kotova.79@gmail.com

Vasily S. Sadov, Ph. D. (Eng.), Assoc. Prof., Prof. of the Department of Intelligent Systems, Faculty of Radiophysics and Computer Technologies, Belarusian State University.
E-mail: sadov@bsu.by

БИОИНФОРМАТИКА

BIOINFORMATICS



УДК 519.23
DOI: 10.37661/1816-0301-2025-22-3-45-58

Оригинальная статья
Original Article

Алгоритм выбора референсных микроРНК при классификации биологических процессов

О. В. Красько^{1✉}, С. В. Якубовский², В. Н. Кипень³

¹Объединенный институт проблем информатики

Национальной академии наук Беларусь,

ул. Сурганова, 6, Минск, 220012, Беларусь

✉E-mail: krasko@newman.bas-net.by

²Белорусский государственный медицинский университет,

пр. Дзержинского, 83, Минск, 220083, Беларусь

E-mail: yakub-2003@yandex.by

³Институт генетики и цитологии

Национальной академии наук Беларусь,

ул. Академическая, 27, Минск, 220072, Беларусь

E-mail: v.kipen@igc.by

Аннотация

Цели. Целью исследования является разработка алгоритма выбора референсных микроРНК с учетом их взаимосвязи с тем, чтобы классифицировать группы образцов при изучении различных биологических процессов.
Методы. Использовались методы линейной алгебры, анализа главных компонент, статистических моделей бинарной регрессии, оценки производительности моделей.

Результаты. Разработан новый алгоритм MDSeek, который предлагает выбор референсных микроРНК для нормализации данных количественной полимеразной цепной реакции с целью последующего использования нормализованных данных для задач классификации. Оценка результатов работы алгоритма для задачи классификации свидетельствует о его более высокой эффективности по сравнению с известными подходами к нормализации результатов полимеразной цепной реакции.

Заключение. В настоящей работе предложен оригинальный алгоритм MDSeek, предназначенный для выбора референсных микроРНК с целью нормализации результатов полимеразной цепной реакции и позволяющий изучать изменения экспрессии микроРНК при сравнении различных биологических процессов. После применения MDSeek на опытном наборе образцов нормализованные данные использовались для задач классификации, метрики производительности были лучше по сравнению с другими алгоритмами.

Ключевые слова: микроРНК, нормализация, полимеразная цепная реакция, классификация, расстояние Махalanобиса, производительность моделей

Для цитирования. Красько, О. В. Алгоритм выбора референсных микроРНК при классификации биологических процессов / О. В. Красько, С. В. Якубовский, В. Н. Кипень // Информатика. – 2025. – Т. 22, № 3. – С. 45–58. – DOI: 10.37661/1816-0301-2025-22-3-45-58.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 17.07.2025

Подписана в печать | Accepted 31.07.2025

Опубликована | Published 30.09.2025

Algorithm for selecting reference microRNAs in biological processes classification

Olga V. Krasko^{1✉}, Siarhei U. Yakubouski², Viachaslau N. Kipen³

¹The United Institute of Informatics Problems of the National Academy of Sciences of Belarus, st. Surganova, 6, Minsk, 220012, Belarus
✉E-mail: krasko@newman.bas-net.by

²Belarusian State Medical University, av. Dzerzhinski, 83, Minsk, 220116, Belarus
E-mail: yakub-2003@yandex.by

³The Institute of Genetics and Cytology of the National Academy of Sciences of Belarus, st. Akademicheskaya, 27, Minsk, 220072, Belarus
E-mail: v.kipen@igc.by

Abstract

Objectives. The algorithm for selection of reference microRNA taking into account their biological features for classification of pathologies.

Development of an algorithm for selecting microRNAs with regard to their interconnection for samples classification in the various biological processes

Methods. Methods of linear algebra, principal component analysis, statistical binary regression models, and model performance metrics were used.

Results. A new algorithm, MDSeek, has been developed that proposes a selection of reference microRNA for the normalization quantitative polymerase chain reaction results taking into account their coexpression. MDSeek demonstrates higher performance metrics compared to known reference gene selection approaches for the subsequent classification tasks.

Conclusion. An original MDSeek algorithm for selecting reference microRNAs for normalization results of polymerase chain reaction is suggested. It takes into account changes in microRNA expression when comparing different biological processes. After applying MDSeek to an experimental set of samples, the normalized data were used for classification tasks, and the performance metrics were better than those of other normalization algorithms.

Keywords: MicroRNA, normalization, polymerase chain reaction, classification, Mahalanobis distance, model performance

For citation. Krasko O. V., Yakubouski S. U., Kipen V. N. *Algorithm for selecting reference microRNAs in biological processes classification*. Informatika [Informatics], 2025, vol. 22, no. 3, pp. 45–58 (In Russ.). DOI: 10.37661/1816-0301-2025-22-3-45-58.

Conflict of interest. The authors declare of no conflict of interest.

Введение. Нормализация в количественной полимеразной цепной реакции (quantitative polymerase chain reaction, qPCR) является критически важным этапом предобработки данных для достижения точной и надежной количественной оценки уровней экспрессии, получаемых в результате qPCR в различных биологических образцах.

Нормализация – это процесс корректировки относительных мер экспрессии между образцами для снижения технических отклонений данных qPCR, не имеющих биологических причин (эффективность qPCR, качество образцов и т. д.), что необходимо для получения биологически значимых и воспроизводимых результатов, которые можно использовать для последующего анализа. Поскольку при выполнении qPCR исследуются относительные значения изменения экспрессии – насколько больше или меньше экспрессируются одни микроРНК относительно других, нормализация предусматривает использование референсных показателей (нормализаторов), по отношению которых изучается экспрессия исследуемых микроРНК. Такими норма-

лизаторами служат молекулы микроРНК, выбор которых может базироваться на различных принципах. Необходимость корректной нормализации подчеркивается получением различных, зачастую противоречивых результатов в ряде исследований, посвященных проблеме изучения экспрессии микроРНК. Некорректная нормализация может приводить к неверной оценке или отсутствию выявления имеющихся изменений в профиле экспрессии микроРНК и сопровождается риском ошибочных выводов при сравнении образцов из разных условий или источников, что делает ее фундаментальным аспектом исследований в области молекулярной биологии [1].

Для повышения надежности результатов qPCR были разработаны различные методы нормализации, базирующиеся на пороговом числе циклов PCR¹ (C_t), включая метод ΔC_t , квантильную нормализацию и рангово-инвариантную нормализацию набора образцов. Метод ΔC_t сравнивает значения порога цикла (C_t) целевых генов со значениями референсных генов. Квантильная и рангово-инвариантная нормализации предлагают более сложные подходы, смягчая технический шум и устранивая зависимость от одного референсного гена соответственно. Вместе с тем в настоящее время не существует единого стандартного подхода к выбору референсной микроРНК, поскольку зависимость от одного показателя может внести значительную ошибку в результаты нормализации [2–4].

Текущие рекомендации предлагают использовать несколько референсных генов, в идеале три или более, чтобы обеспечить надежную нормализацию, которая может учитывать присущую изменчивость различных тканей и экспериментальных условий. Такая практика соответствует рекомендациям MIQE, направленным на стандартизацию методологий qPCR и улучшение воспроизводимости в исследованиях [5].

Применение нормализованных данных qPCR охватывает различные области, включая исследования рака, биологию развития и фармакогеномику, где они облегчают анализ паттернов экспрессии генов, относящихся к болезням и ответам на лечение. Продолжающаяся эволюция стратегий и инструментов нормализации повышает надежность и воспроизводимость результатов qPCR, устранивая сложности, связанные с анализом экспрессии генов [6].

Таким образом, нормализация как процесс предобработки пытается решить проблемы, связанные со следующими факторами:

1) контролем за вариациями, поскольку в экспериментах с использованием qPCR существует множество факторов, которые могут вызвать вариации в результатах, такие как количество исходной РНК, эффективность обратной транскрипции и qPCR, качество образцов и т. д. Нормализация помогает контролировать эти вариации, что делает данные более сопоставимыми;

2) снижением экспериментальных ошибок, поскольку нормализация позволяет учитывать технические вариации между образцами, что повышает точность данных;

3) калибровкой данных, так как нормализация с использованием референсных генов помогает откалибровать результаты экспрессии целевых генов, чтобы снизить технические и биологические вариации;

4) унификацией при сравнительных исследованиях, когда необходимо выявить дифференциальную экспрессию генов.

Многие методы нормализации основаны на предположении, что один или несколько генов конститутивно экспрессируются на почти постоянных уровнях при всех экспериментальных условиях и уровни экспрессии всех генов в образце нормализуются с учетом этого предположения.

1. Основные стратегии выбора референсных генов, основанные на ΔC_t . Предполагается, что имеется матрица количественных данных размером $N \times K$, где N – число рассматриваемых генов, K – число образцов исследуемого материала. Каждая ячейка матрицы содержит значение C_t – число циклов PCR, при котором флуоресценция превышает пороговое значение для n -го гена в k -м образце.

¹Пороговое число циклов (ΔC_t) – это число циклов PCR, при котором флуоресценция превышает пороговое значение.

Рассмотрим следующие алгоритмы:

1. Алгоритм BestKeeper [7] предназначен для выбора стабильных референсных генов для использования в исследованиях экспрессии генов с помощью qPCR. Основные шаги алгоритма:

1. Расчет стандартного отклонения: для каждого кандидата в референсные гены вычисляется стандартное отклонение (*SD*) и среднее значение (*Mean*) C_t значений во всех образцах.

2. Оценка стабильности: стабильность каждого кандидата в референсные гены оценивается по соотношению стандартного отклонения к среднему значению (*SD / Mean*). Наименьшие значения этого соотношения указывают на наибольшую стабильность.

3. Выбор референсных генов: из всех кандидатов выбираются те, которые имеют наименьшие значения соотношения (*SD / Mean*), т. е. наиболее стабильные.

2. Алгоритм geNorm [1] также предназначен для выбора наиболее стабильных референсных генов для нормализации данных qPCR. Он основан на оценке стабильности генов путем анализа их выраженной в различных образцах. Основные шаги алгоритма:

1. Расчет коэффициента стабильности M для каждого гена, основанного на среднегеометрической парной вариации между генами. Гены с наименьшим значением M считаются наиболее стабильными.

2. Постепенное исключение менее стабильных генов: на каждом шаге исключается ген с наибольшим значением M , и процесс повторяется до тех пор, пока не останутся два гена. Таким образом, в каждом цикле исключается наименее стабильный ген.

3. Определение оптимального числа референсных генов путем расчета коэффициента вариации (V) для последовательных пар генов. Если коэффициент вариации V между генами n и $n+1$ ниже заданного порогового значения (например, 0,1), считается, что добавление дополнительного гена не улучшит точность нормализации.

4. Расчет нормализационного фактора (NF) для каждого образца как среднегеометрического значения экспрессии выбранных референсных генов в данном образце на основе выбранных стабильных генов.

3. Алгоритм NormFinder (два варианта: с группами и без групп) [8] – это статистический метод для выбора наиболее стабильных референсных генов с целью нормализации данных qPCR. Основные шаги алгоритма:

1. Расчет внутригрупповой и межгрупповой вариации. Внутригрупповая вариация – это вариация C_t значений одного гена внутри одной группы образцов, межгрупповая вариация – вариация средних C_t значений одного гена между разными группами образцов.

2. Расчет комбинированной стабильности для каждого гена. Алгоритм вычисляет комбинированную меру стабильности для каждого гена, объединяя внутригрупповую и межгрупповую вариации. Гены с наименьшей комбинированной мерой стабильности считаются наиболее стабильными и подходят для использования в качестве референсных.

3. Ранжирование генов: все кандидаты ранжируются по их комбинированной стабильности. Те, у кого эта мера наименьшая, считаются наиболее стабильными и рекомендованы для использования в качестве референсных.

Преимущества алгоритма:

- учет вариаций. Алгоритм NormFinder учитывает как внутригрупповую, так и межгрупповую вариацию, что делает его особенно полезным при анализе сложных данных;

- различное число групп. Алгоритм NormFinder может быть применен как к набору образцов с одним классом, так и к данным с несколькими классами.

4. Алгоритм NormiRAZOR [9] является математической комбинацией всех перечисленных выше алгоритмов. Он осуществляет полный перебор сочетаний $C_n^m = \frac{N!}{(N-M)! \times M!}$, где N –

число рассматриваемых генов, M – число генов, которые выбраны как референсные. Для каждого сочетания рассчитываются меры стабильности для четырех вариантов: BestKeeper,

geNorm, NormFinder (два варианта: с классами и без них). Далее проводится ранжирование по всем сочетаниям по каждому алгоритму отдельно и рассчитываются ранги всех сочетаний по каждому алгоритму отдельно. Ранги приводятся к единичному диапазону. Для каждого сочетания определяется комбинированный ранг как среднее четырех рангов (единичного интервала). Окончательное ранжирование сочетаний проводится по усредненному рангу. Выбор сочетания, которое будет набором референсных генов, остается за исследователем.

Разные стратегии могут значительно исказить способность нахождения различий между группами образцов, связанных с рядом заболеваний (формами заболевания), и, безусловно, являются существенным недостатком при сравнении уровней экспрессии между различными исследованиями. В дополнение к стандартизации сбора и обработки образцов использование конкретной процедуры нормализации обеспечит лучшую воспроизводимость, а определение эндогенных эталонных генов расширит возможности проведения крупномасштабных анализов на выбранных маркерах [10].

2. Особенности анализа данных экспрессии микроРНК. МикроРНК – это короткие (18–24 нуклеотида) некодирующие молекулы РНК, играющие важную роль в регуляции экспрессии генов. Показано, что мишениями микроРНК являются от 30 до 60 % генов человека, кодирующих разнообразные белки [11]. Было установлено, что молекулы данного типа экспрессируются в опухолях различного генеза, их аберрантная экспрессия играет важную роль в пролиферации, дифференцировке, инвазии, миграции и апоптозе опухолевых клеток [12]. Усиленная экспрессия микроРНК может быть связана с возникновением злокачественной опухоли, и такие микроРНК являются онкогенными. Подавление экспрессии микроРНК зачастую подавляет и развитие опухоли. Описаны также микроРНК с опухоль-супрессорной активностью. Показано, что функция каждой микроРНК может быть ткане- и контекст-специфичной [13].

МикроРНК являются ключевыми игроками в сложных биологических процессах, нарушения их экспрессии связаны, помимо опухолей, с развитием многих других заболеваний, включая сердечно-сосудистые, нейродегенеративные и инфекционные. Это обуславливает возможность использования микроРНК в качестве диагностических и прогностических биомаркеров широкого спектра заболеваний. Изучение микроРНК помогает понять механизмы развития различных заболеваний и разработать новые методы их диагностики и лечения.

Особенностью экспрессии микроРНК являются ее высокая вариабельность и корреляция между изучаемыми микроРНК.

Биологическая вариабельность обусловлена гетерогенностью клеток. В различных клеточных типах и тканях уровни экспрессии микроРНК могут существенно различаться. Это усложняет интерпретацию результатов, поскольку они могут отражать не только интересующее исследователей состояние, но и общую клеточную гетерогенность. Также уровень микроРНК может изменяться в зависимости от физиологических состояний организма, таких как стресс, воспаление, диета, возраст и т. д.

Корреляция определена коэкспрессией микроРНК, в некоторых случаях несколько микроРНК могут коэкспрессироваться и оказывать схожие эффекты на экспрессию генов. Это может затруднять выделение вкладов отдельных микроРНК в общий результат [14].

В отличие от генов, которые могут быть конститутивно обусловлены, микроРНК являются гибким биологическим инструментом в регуляции экспрессии самих генов. Таким образом, изучение микроРНК является контекстуальным и в первую очередь зависит от конкретной решаемой задачи. Одной из таких задач является задача классификации, и в настоящей работе предлагается включить в процесс выбора референсных микроРНК метрики, связанные с различием классов (изучаемых вариантов опухолевого процесса) изначально, для того чтобы комплексно решать задачу нормализации совместно с задачей классификации. Такие алгоритмы, как BestKeeper и geNorm, изначально не включают классы. Алгоритм NormFinder включает как внутригрупповую, так и межгрупповую вариацию, но не учитывает корреляцию между Ct различных микроРНК, что характерно и важно для биологических процессов.

3. Предлагаемый алгоритм (MDSeek). При выборе референсных микроРНК предлагается рассмотреть такую метрику, как расстояние Махalanобиса [15, 16], основной смысл использования которой – учет дисперсий и ковариаций пространства признаков. Также особенностью

предлагаемого метода выбора является возможность анализа пространства признаков (исследуемых микроРНК), который превышает размер образцов определенного класса.

Пусть имеется N рассматриваемых микроРНК (признаков), которые получены для K образцов тканей. Образцы могут принадлежать G различным классам (изучаемые патологии). Составляются интересующие сочетания или полный перебор сочетаний, общее число

$$V = C_n^m = \frac{N!}{(N-M)! \times M!}, \text{ где } N - \text{число рассматриваемых признаков, } M - \text{число признаков,}$$

которые выбраны как референсные.

При рассмотрении конкретного сочетания референсных микроРНК $v \in V$ выполняются алгоритмы, состоящие из следующих шагов:

1. Для получения матрицы нормализованных значений $\|\Delta Ct\|_v$ для каждого образца рассчитывается вектор ΔCt длиной $(N-M)$ как разность между значением каждого признака и сочетанием референсных микроРНК. Комбинацией значений референсных микроРНК является их среднее (арифметическое или геометрическое [7]).

2. Выделяются образцы только одного из классов из $\|\Delta Ct\|_v$ и рассчитывается матрица ковариаций признаков $\text{cov}(g, v)$ каждого класса, $g = 1, \dots, G$. Если хотя бы одна из матриц не обратима, то используем метод усадки (shrinkage) ковариационной матрицы [17] для всех классов, который применим в задачах с небольшим количеством образцов и большим количеством признаков (микроРНК), и получаем $\text{cov}_*^{-1}(g, v)$. Если все матрицы обратимы, то далее используем $\text{cov}_*^{-1}(g, v) = \text{cov}^{-1}(g, v)$.

3. Рассчитывается центроид $\text{centroid}(g, v)$ признаков каждого класса $g = 1, \dots, G$ как среднее каждого признака в классе.

4. Число пар сравниваемых классов определяем как число сочетаний $C_G^2 = \frac{G!}{(G-2)! \times 2!}$.

5. Рассчитывается общая ковариационная матрица двух классов как

$$\text{cov}(p, q, v) = \left((n_p - 1) \times \text{cov}(p, v) + (n_q - 1) \times \text{cov}(q, v) \right) / (n_p + n_q - 2),$$

где n_p, n_q – число образцов в соответствующих классах $p, q \in G$.

6. Расстояние Махalanобиса определяется для центроидов пары классов

$$MD_{pq}^v = MD\left(\text{centroid}(p, v), \text{centroid}(q, v), \text{cov}^{-1}(p, q, v)\right) = \\ = \sqrt{\left(\text{centroid}(p, v) - \text{centroid}(q, v)\right) \times \text{cov}^{-1}(p, q, v) \times \left(\text{centroid}(p, v) - \text{centroid}(q, v)\right)^T}.$$

7. Для выбранного сочетания v референсных микроРНК определяется сумма расстояний Махalanобиса по всем парам класса, повторяя пп. 5, 6 для каждой пары классов.

8. Пп. 1–7 повторяются для каждого сочетания $v \in V$ референсных микроРНК.

9. Находится сочетание микроРНК (признаков), для которых сумма расстояний Махalanobisа по всем парам сравниваемых классов максимальна. Данное сочетание будет использовано как референсное.

4. Сравнительные результаты решения классификационной задачи при различных алгоритмах нормализации. Для проверки эффективности классификации предложенного алгоритма был использован набор образцов, содержащий данные о профиле экспрессии микроРНК и полученный на материале 299 гистологических образцов ткани щитовидной железы

(169 образцов злокачественных опухолей и 130 образцов доброкачественных опухолей). Все образцы представляли собой операционный материал пациентов, проходивших лечение в учреждении здравоохранения «Минский городской клинический онкологический центр» в период 2021–2023 гг. Молекулярно-генетические исследования выполнены на базе Института генетики и цитологии Национальной академии наук Беларусь. Исследование одобрено Комитетом по биомедицинской этике учреждения образования «Белорусский государственный медицинский университет» Министерства здравоохранения Республики Беларусь (протокол № 9 от 23.03.2022). Все данные, полученные из медицинских записей, были анонимизированы.

Методом qPCR были получены пороговые значения *Ct* 18 микроРНК для каждого образца. На основании проведенного анализа научных публикаций об информативности микроРНК в диагностике злокачественных опухолей щитовидной железы были отобраны следующие микроРНК (табл. 1).

Таблица 1
Перечень исследованных микроРНК

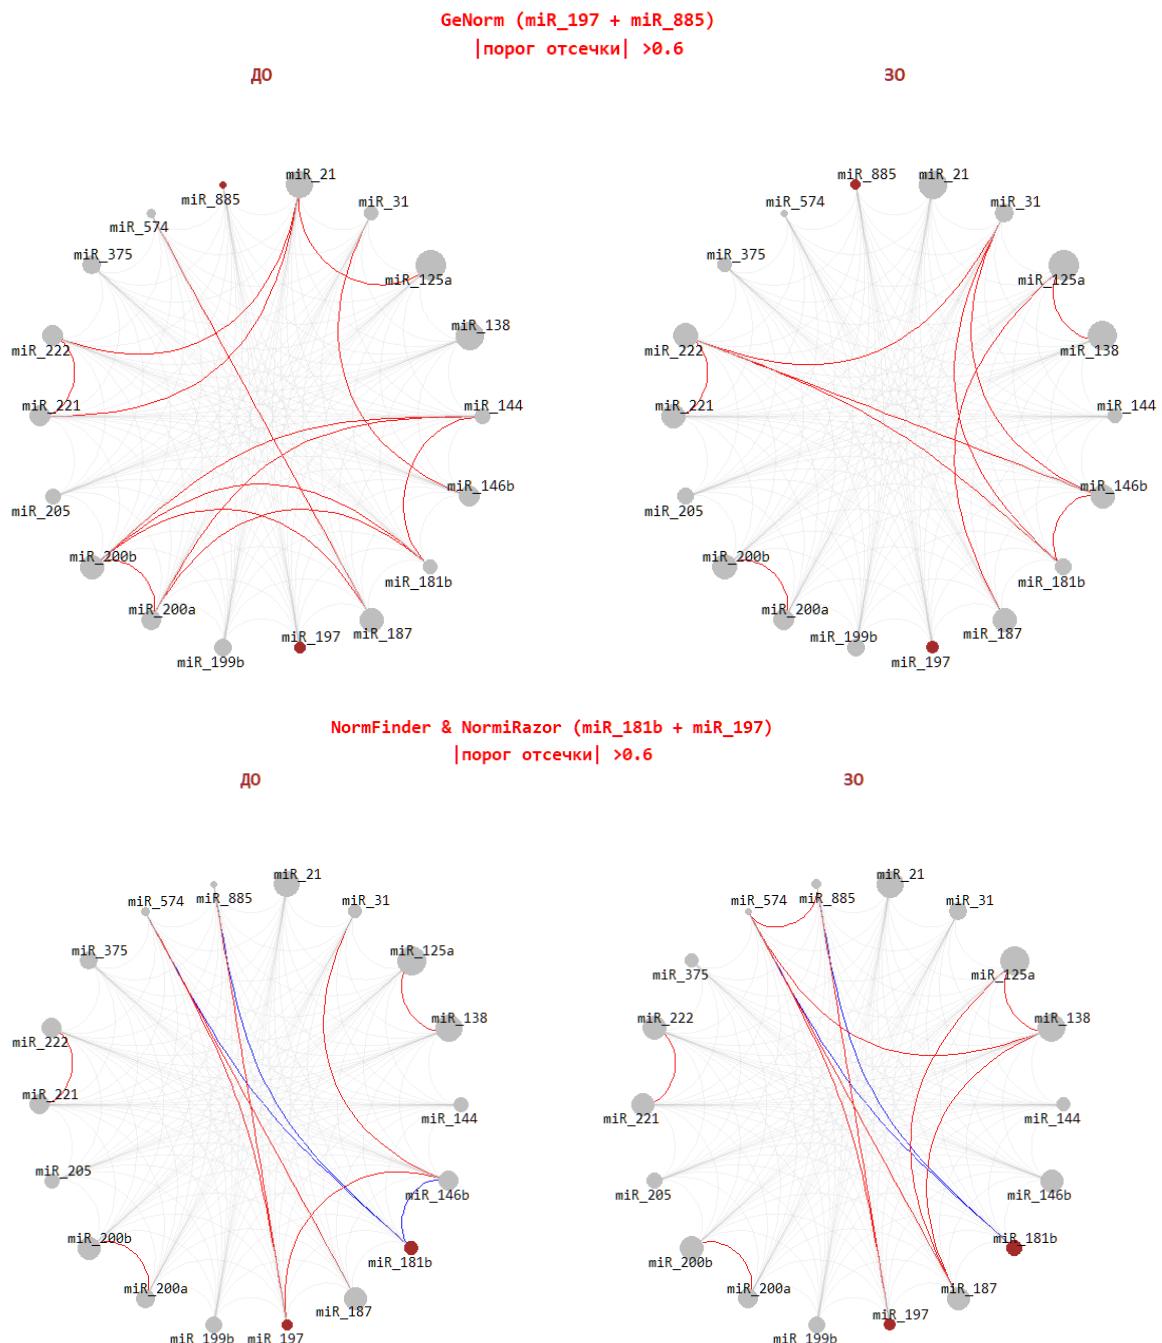
Table 1
List of microRNA examined

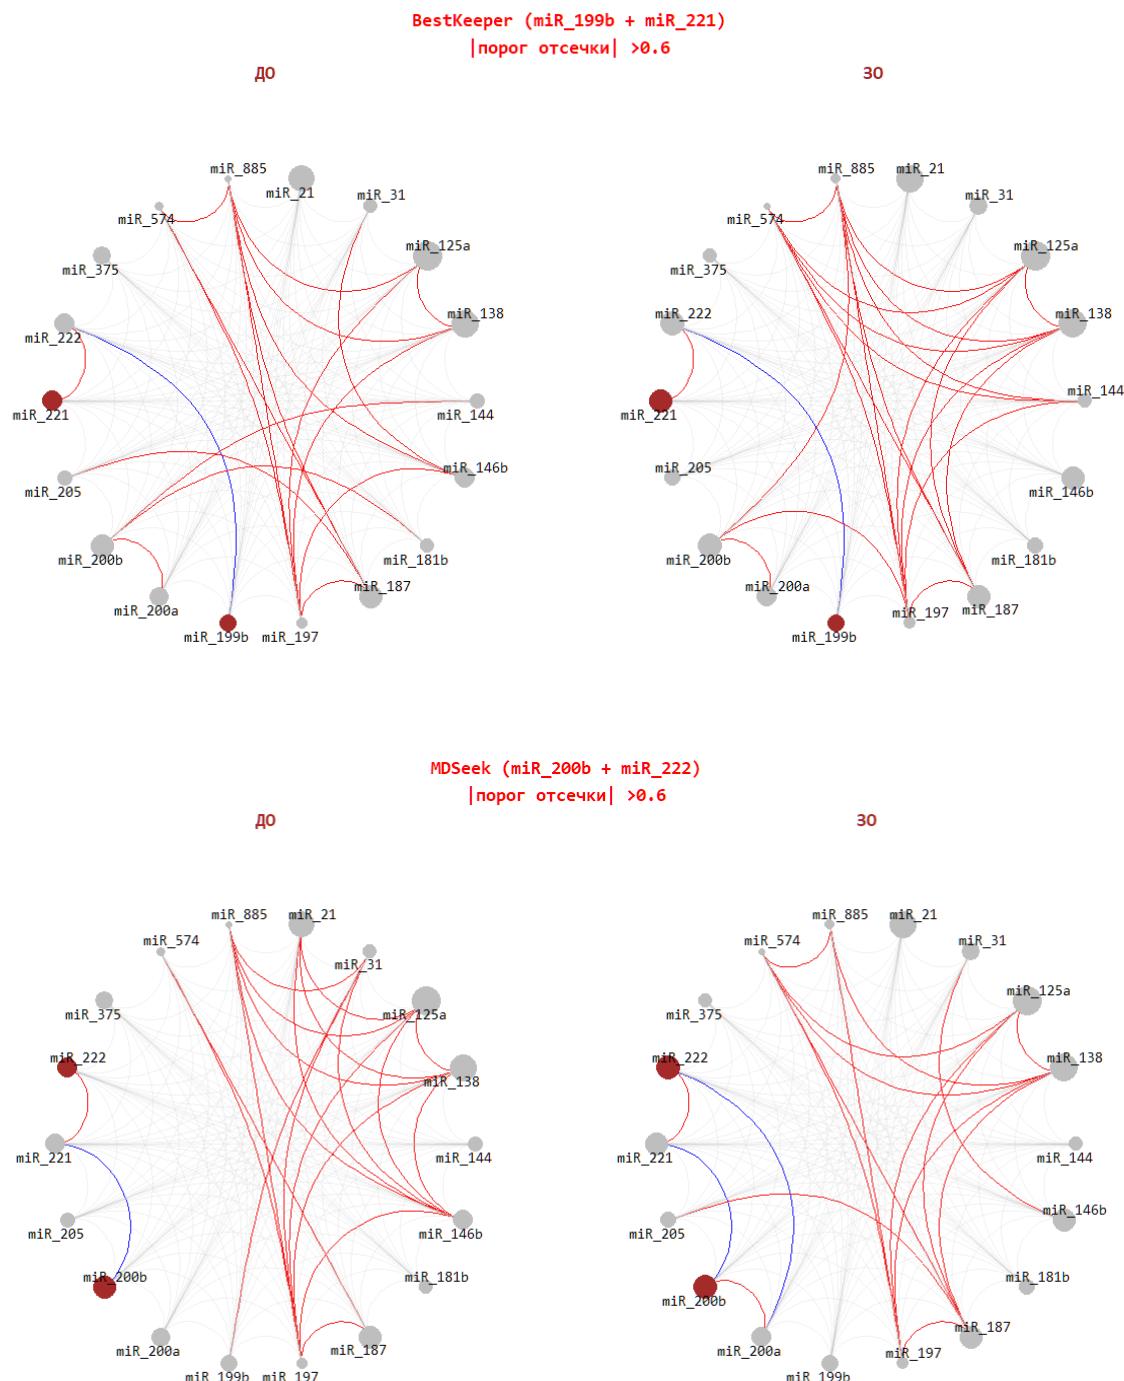
МикроРНК <i>MicroRNA</i>	Индивидуальный номер* <i>Individual number*</i>	Хромосомная локализация** <i>Chromosomal localization**</i>	Краткое обозначение в исследовании <i>Brief designation in the study</i>
hsa-miR-021-5p	MIMAT0000076	chr17: 59841266-59841337	miR_21
hsa-miR-031-5p	MIMAT0000089	chr9: 21512115-21512185	miR_31
hsa-miR-125a-3p	MIMAT0004602	chr19: 51693254-51693339	miR_125a
hsa-miR-138-5p	MIMAT0000430	chr3: 44114212-44114310	miR_138
hsa-miR-144-5p	MIMAT0004600	chr17: 28861533-28861618	miR_144
hsa-miR-146b-5p	MIMAT0002809	chr10: 102436512-102436584	miR_146b
hsa-miR-181b-5p	MIMAT0000257	chr1: 198858873-198858982	miR_181b
hsa-miR-187-3p	MIMAT0000262	chr18: 35904818-35904926	miR_187
hsa-miR-197-3p	MIMAT0000227	chr1: 109598893-109598967	miR_197
hsa-miR-199b-5p	MIMAT0000263	chr9: 128244721-128244830	miR_199b
hsa-miR-200b-3p	MIMAT0000318	chr1: 1167104-1167198	miR_200b
hsa-miR-200a-3p	MIMAT0000682	chr1: 1167863-1167952	miR_200a
hsa-miR-205-5p	MIMAT0000266	chr1: 209432133-209432242	miR_205
hsa-miR-221-3p	MIMAT0000278	chrX: 45746157-45746266	miR_221
hsa-miR-222-3p	MIMAT0000279	chrX: 45747015-45747124	miR_222
hsa-miR-375-3p	MIMAT0000728	chr2: 219001645-219001708	miR_375
hsa-miR-574-3p	MIMAT0003239	chr4: 38868032-38868127	miR_574
hsa-miR-885-5p	MIMAT0004947	chr3: 10394489-10394562	miR_885

Примечание: *<https://www.mirbase.org/>

**https://www.ncbi.nlm.nih.gov/datasets/genome/GCF_000001405.26/

На полученном наборе данных выполнен поиск пар кандидатов в референсные микроРНК по алгоритмам BestKeeper, NormFinder, geNorm, NormiRAZOR и предложенному алгоритму MDseek, отобраны пары кандидатов в референсные микроРНК (табл. 2). Комбинация значений референсных микроРНК рассчитывалась как арифметическое среднее.

Рис. 1. Корреляционная структура матриц $\|\Delta Ct\|$,Fig. 1. Correlation structure of matrices $\|\Delta Ct\|$,



полученных по различным алгоритмам

obtained by different algorithms

Для каждого из исследуемых алгоритмов определены пары микроРНК, которые можно считать кандидатами в референсные гены, и рассчитаны матрицы нормализованных значений $\|\Delta Ct\|$ в пределах каждого алгоритма.

Таблица 2

Перечень пар-кандидатов в референсные микроРНК по различным алгоритмам

Table 2

List of the best reference microRNA pairs according to different algorithms

Алгоритм <i>Algorithm</i>	Лучшее сочетание пар микроРНК <i>The best combination of microRNA pairs</i>
BestKeeper	miR_199b + miR_221
NormFinder	miR_181b + miR_197
geNorm	miR_197 + miR_885
NormiRAZOR	miR_181b + miR_197
MDSeek	miR_200b + miR_222

Далее была рассмотрена корреляционная структура микроРНК в группах доброкачественных и злокачественных образцов тканей на базе нормализованных матриц с порогом отсечки коэффициента корреляции по Спирмену на уровне 0,6. Был проведен анализ главных компонент в пределах каждого алгоритма и выбранной пары (табл. 2) среди микроРНК, не попавших в кандидаты референсных (16 нормализованных микроРНК), и проанализирована доля объясненной дисперсии, построена логистическая бинарная регрессия на первых двух компонентах, которые получены на предыдущем шаге, и оценены основные метрики ее производительности.

Корреляционная структура показана на рис. 1. Вычислялась корреляция по Спирмену между парами признаков. Красным цветом выделены связи при значении $\rho > 0,6$, синим – $\rho < -0,6$ на основании различных алгоритмов. Размер узла определяет силу экспрессии, бордовым цветом выделены узлы референсных микроРНК в пределах изучаемого алгоритма. ДО – доброкачественная опухоль, ЗО – злокачественная опухоль.

Как видно на рис. 1, различие патологических процессов нарушает взаимодействие некоторых микроРНК, что может являться основанием для дальнейших исследований биологических процессов. В наибольшей степени это заметно при использовании референсных микроРНК, отобранных по алгоритму MDseek.

На рис. 2 и 3 показаны результаты анализа методом главных компонент – доля объясненной вариации и диаграмма рассеяния двух первых компонент в отношении двух исследуемых классов. В табл. 3 и 4 приведены метрики производительности бинарных логистических моделей, построенных на двух первых компонентах.

Таблица 3

Доля объясненной вариации после применения различных алгоритмов нормализации

Table 3

Proportion of explained variation after applying different normalization algorithms

Алгоритм <i>Algorithm</i>	Доля объясненной вариации <i>Proportion of explained variation</i>	
	на двух первых компонентах <i>in the first two components</i>	на трех первых компонентах <i>in the first three components</i>
geNorm	47,5	58,5
NormiRazor, NormFinder & NormFinder with groups	40,7	53,6
BestKeeper	52,3	63,1
MDseek	59,8	70,1

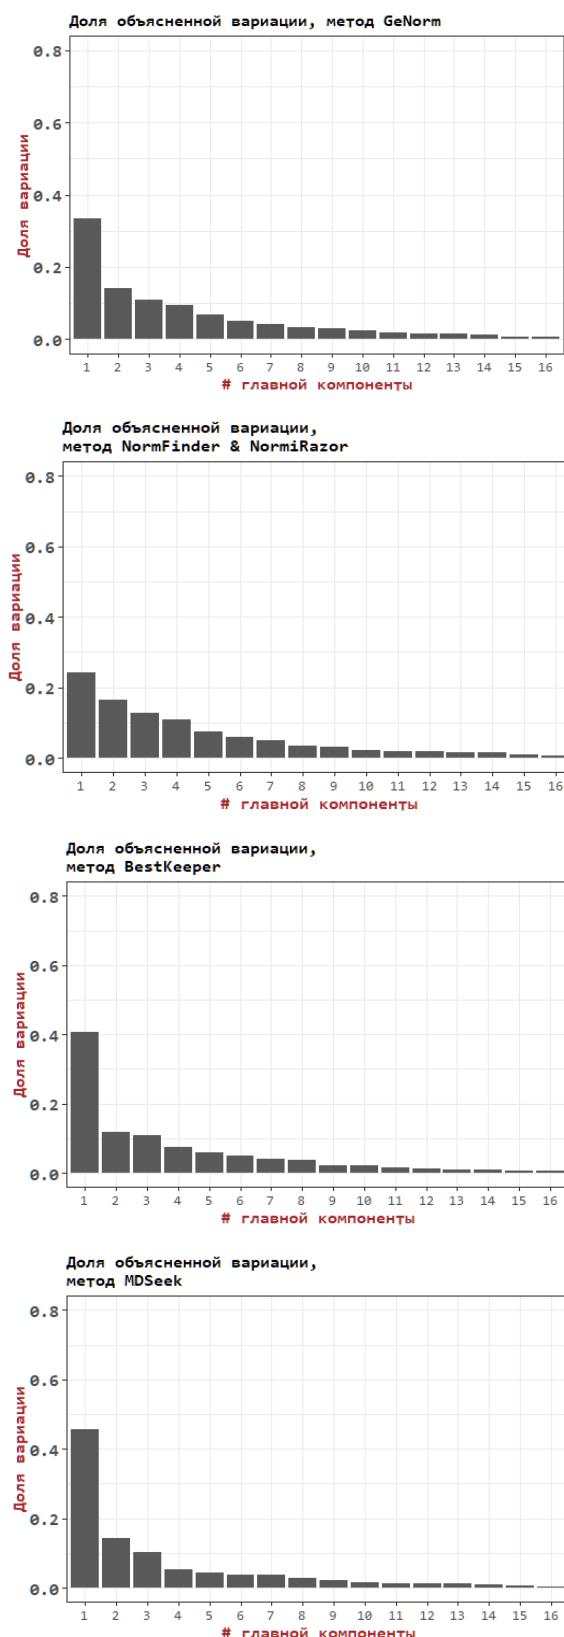


Рис. 2. Вклад компонент в объяснение вариации при использовании различных методов выбора референсных генов

Fig. 2. Component contributions to explaining variation when using different methods for selecting reference genes

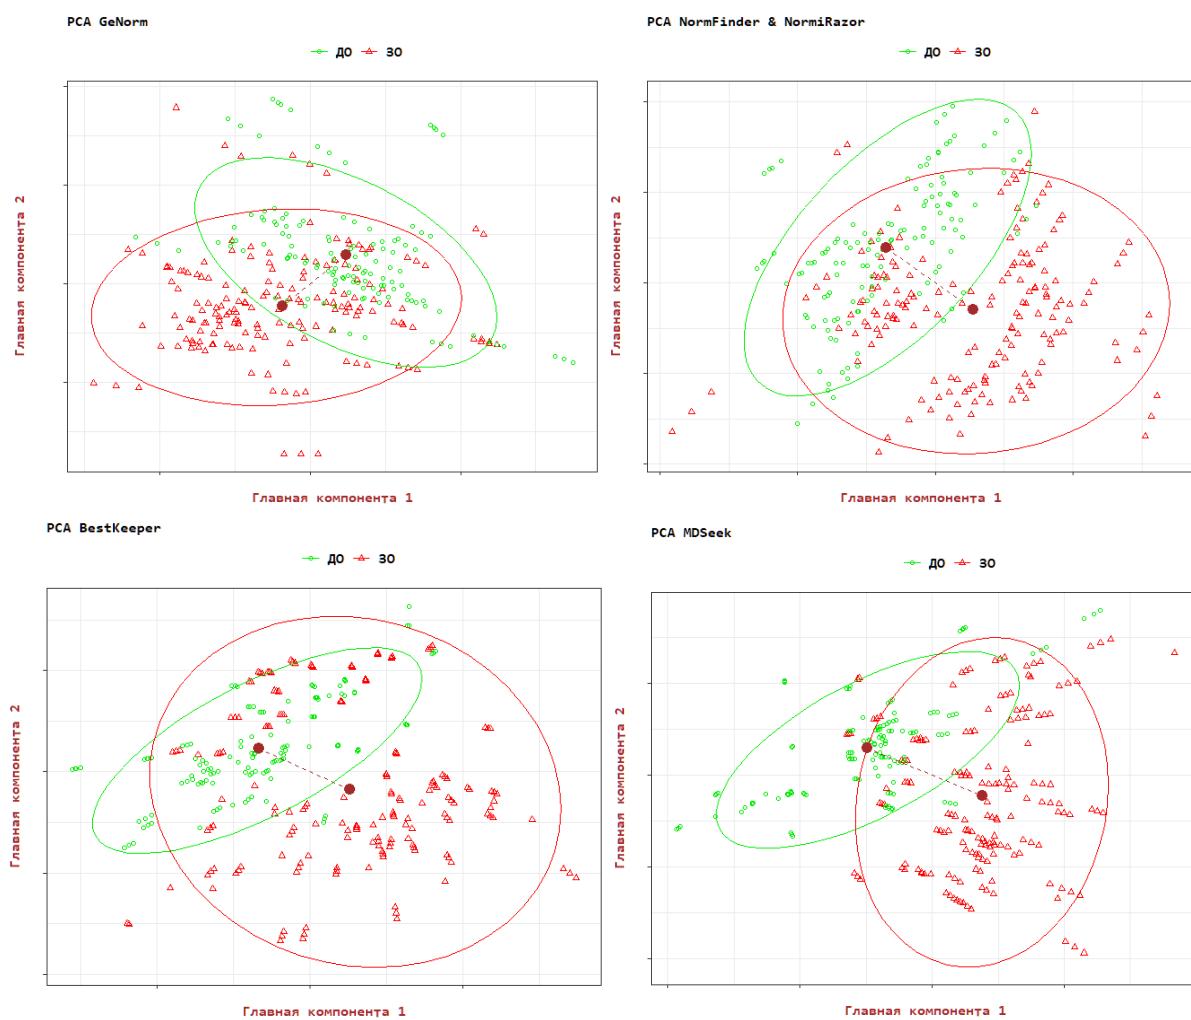


Рис. 3. Диаграмма рассеяния двух первых главных компонент при использовании различных алгоритмов выбора референсных миРНК

Fig. 3. Scatterplot of the first two principal components for different algorithms for selecting reference microRNA

Таблица 4

Метрики производительности логистической регрессии

Table 4

Logistic regression performance metrics

Алгоритм <i>Algorithm</i>	AUC	Чувствительность <i>Sensitivity</i>	Специфичность <i>Specificity</i>	Прогностическая цен- ность положительного результата <i>Positive predictive value</i>	Прогностическая цен- ность отрицательного результата <i>Negative predictive value</i>	Аккуратность <i>Accuracy</i>
geNorm	0,84 (0,80–0,89)	0,77	0,86	0,88	0,74	0,81
NormiRazor, NormFinder & NormFinder with groups	0,90 (0,86–0,93)	0,70	0,95	0,95	0,71	0,81
BestKeeper	0,83 (0,79–0,88)	0,68	0,89	0,68	0,56	0,77
MDseek	0,95 (0,92–0,97)	0,88	0,86	0,89	0,84	0,87

Как следует из табл. 3 и 4, предложенный алгоритм нормализации набора признаков (микроРНК) объясняет больше вариаций и позволяет в дальнейшем строить классификационные модели с лучшими характеристиками производительности.

Полученные результаты позволяют сделать следующие выводы:

1. В отличие от генов микроРНК не являются конститутивными в биологическом организме, что затрудняет или делает невозможным выбор внешних референсных стабильных микроРНК.

2. Корреляция экспрессии отдельных микроРНК с различными биологическими процессами делает возможным учет профиля экспрессии в зависимости от типа ткани, а традиционные алгоритмы нормализации могут быть дополнены компонентами, которые учитывают структуру взаимодействия микроРНК в зависимости от биологического процесса.

3. Предложенный алгоритм MDSeek показал лучшие параметры производительности и может в дальнейшем использоваться для анализа биологических процессов и разработки диагностических биомаркеров (заявка a20250134. Дата приоритета 16.06.2025 г.).

Заключение. Предложен новый алгоритм MDSeek выбора референсных микроРНК при исследовании экспрессии методом кПЦР. Согласно проведенному исследованию данный алгоритм выбора референсных микроРНК для дальнейшей классификации обладает лучшими характеристиками производительности, поскольку учитывает наличие коэкспрессии микроРНК при различных патологических процессах, что может быть использовано для анализа биологических процессов и разработки диагностических биомаркеров. Выбор алгоритма нормализации экспрессии микроРНК критически важен для оптимизации подходов к дифференциальной диагностике опухолей, лечению и прогнозированию течения заболевания, позволяет более эффективно использовать потенциал микроРНК как биомаркеров и терапевтических мишней в онкологии.

Вклад авторов. О. В. Красько – дизайн статьи, разработка алгоритма, сравнение результатов, оформление статьи. С. В. Якубовский – участие в получении первичного материала, редактирование текста статьи. В. Н. Кипень – проведение молекулярно-генетических исследований, редактирование текста статьи.

References

1. Vandesompele J., De Preter K., Pattyn F., Poppe B., Van Roy N., ..., Speleman F. Accurate normalization of real-time quantitative RT-PCR data by geometric averaging of multiple internal control genes. *Genome Biology*, 2002, vol. 3, pp. 1–12.
2. Karlen Y., McNair A., Persegues S., Mazza C., Mermel N. Statistical significance of quantitative PCR. *BMC Bioinformatics*, 2007, vol. 8, pp. 1–16.
3. Maltseva D. V., Khaustova N. A., Fedotov N. N., Matveeva E. O., Lebedev A. E., ..., Tonevitsky A. G. High-throughput identification of reference genes for research and clinical RT-qPCR analysis of breast cancer samples. *Journal of Clinical Bioinformatics*, 2013, vol. 3, pp. 1–12.
4. Mar J. C., Kimura Y., Schroder K., Irvine K. M., Hayashizaki Y., ..., Quackenbush J. Data-driven normalization strategies for high-throughput quantitative RT-PCR. *BMC Bioinformatics*, 2009, vol. 10, pp. 1–10.
5. Bustin S. A., V. Benes, J. A Garson, J. Hellemans, J. Huggett, ..., Wittwer C. T. The MIQE guidelines: minimum information for publication of quantitative real-time PCR experiments. *Clinical Chemistry*, 2009, vol. 55, no. 4, pp. 611–622.
6. Jacob F., Guertler R., Naim S., Nixdorf S., Fedier A., ..., Heinzelmann-Schwarz V. Careful selection of reference genes is required for reliable performance of RT-qPCR in human normal and cancer cell lines. *PloS One*, 2013, vol. 8, no. 3, p. e59180.
7. Pfaffl M. W., Tichopad A., Prgomet C., Neuvians T. P. Determination of stable housekeeping genes, differentially regulated target genes and sample integrity: BestKeeper – Excel-based tool using pair-wise correlations. *Biotechnology Letters*, 2004, vol. 26, pp. 509–515.

8. Andersen C. L., Jensen J. L., Ørntoft T. F. Normalization of real-time quantitative reverse transcription-PCR data: a model-based variance estimation approach to identify genes suited for normalization, applied to bladder and colon cancer data sets. *Cancer Research*, 2004, vol. 64, no. 15, pp. 5245–5250.
9. Gracia S., Smyczynska U., Pagacz K., Fendler W. NormiRazor: tool applying GPU-accelerated computing for determination of internal references in microRNA transcription studies. *BMC Bioinformatics*, 2020, vol. 21, pp. 1–16.
10. Marabita F., de Candia P., Torri A., Tegnér J., Abrignani S., Rossi R. L. Normalization of circulating microRNA expression data obtained by quantitative real-time RT-PCR. *Briefings in Bioinformatics*, 2016, vol. 17, no. 2, pp. 204–212.
11. Friedman R. C., Farh K. K., Burge C. B., Bartel D. P. Most mammalian mRNAs are conserved targets of microRNAs. *Genome Research*, 2009, vol. 19, no. 1, pp. 92–105. DOI: 10.1101/gr.082701.108.
12. Iorio M. V., Croce C. M. MicroRNA dysregulation in cancer: diagnostics, monitoring and therapeutics. A comprehensive review. *EMBO Molecular Medicine*, 2012, vol. 4, no. 3, pp. 143–159. DOI: 10.1002/emmm.201100209.
13. Bouhraquech M., Klubo-Gwiezdinska J., Kebebew E. MicroRNAs in the thyroid. *Best Practice & Research Clinical Endocrinology & Metabolism*, 2016, vol. 30, iss. 5, pp. 603–619. DOI: 10.1016/j.beem.2016.10.001.
14. Yoshida K., Yokoi A., Yamamoto Y., Kajiyama H. ChrXq27.3 miRNA cluster functions in cancer development. *Journal of Experimental & Clinical Cancer Research*, 2021, vol. 40, iss. 1, p. 112. DOI: 10.1186/s13046-021-01910-0.
15. Mahalanobis, P. C. On the generalized distance in statistics. *Proceedings of National Institute Science in India*, 1936, vol. 2, pp. 49–55.
16. De Maesschalck R., Jouan-Rimbaud D., Massart D. L. The mahalanobis distance. *Chemometrics and Intelligent Laboratory Systems*, 2000, vol. 50, no. 1, pp. 1–18.
17. Touloumis A. Nonparametric Stein-type shrinkage covariance matrix estimators in high-dimensional settings. *Computational Statistics & Data Analysis*, 2015, vol. 83, pp. 251–261.

Информация об авторах

Красько Ольга Владимировна, кандидат технических наук, доцент, ведущий научный сотрудник, Объединенный институт проблем информатики Национальной академии наук Беларусь.

E-mail: krasko@newman.bas-net.by
<https://orcid.org/0000-0002-4150-282X>

Якубовский Сергей Владимирович, кандидат медицинских наук, доцент, доцент кафедры хирургии и трансплантологии с курсом повышения квалификации и переподготовки, Белорусский государственный медицинский университет.

E-mail: yakub-2003@yandex.by
<https://orcid.org/0000-0003-3759-7050>

Кипен Вячеслав Николаевич, кандидат биологических наук, доцент, ведущий научный сотрудник, Институт генетики и цитологии Национальной академии наук Беларусь.

E-mail: v.kipen@igc.by
<https://orcid.org/0000-0002-7822-0746>

Information about the authors

Olga V. Krasko, Ph. D. (Eng.), Assoc. Prof., Leading Researcher, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus.

E-mail: krasko@newman.bas-net.by
<https://orcid.org/0000-0002-4150-282X>

Siarhei U. Yakubouski, Ph. D. (Med.), Assoc. Prof., Assoc. Prof. of Department of Surgery and Transplantology with Advanced Training and Retraining Courses, Belarusian State Medical University.

E-mail: yakub-2003@yandex.by
<https://orcid.org/0000-0003-3759-7050>

Viachaslau N. Kipen, Ph. D. (Biol.), Assoc. Prof., Leading Researcher, The Institute of Genetics and Cytology of the National Academy of Sciences of Belarus.

E-mail: v.kipen@igc.by
<https://orcid.org/0000-0002-7822-0746>

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ MATHEMATICAL MODELING



УДК 519.6:537.2
DOI: 10.37661/1816-0301-2025-22-3-59-71

Оригинальная статья
Original Article

Аналитическое решение задачи экранирования низкочастотного магнитного поля тонкими сферическими экранами

Г. Ч. Шушкевич

Гродненский государственный университет им. Янки Купалы,
ул. Ожешко, 22, Гродно, 230023, Беларусь
E-mail: gsys@grsu.by

Аннотация

Цели. Целями работы являются построение аналитического решения задачи экранирования низкочастотного магнитного поля двумя тонкими непересекающимися сферическими экранами, расположенными на поверхности сферы, и вычисление коэффициента экранирования исходного магнитного поля сферическими экранами.

Методы. Для решения поставленной граничной задачи используются метод теорем сложения и метод тройных сумматорных уравнений. Потенциал исходного магнитного поля представляется в виде сферических гармонических функций. Вторичные потенциалы магнитного поля представляются в виде суперпозиции сферических гармонических функций в локальной системе координат в трехмерном пространстве. Результаты. Решение поставленной граничной задачи сведено к решению системы интегральных уравнений Фредгольма второго рода относительно специальным образом введенных функций. Численно исследовано влияние геометрических параметров задачи на значение коэффициента экранирования. Результаты вычислений представлены в виде графиков.

Заключение. Предложенная методика и разработанное программное обеспечение могут найти практическое применение при конструировании экранов в различных областях техники.

Ключевые слова: граничная задача, магнитное поле, потенциал, теоремы сложения, гармонические функции, тройные сумматорные уравнения

Благодарность. Работа выполнялась в рамках подпрограммы «Математические модели и методы» Государственной программы научных исследований «Конвергенция 2025».

Для цитирования. Шушкевич, Г. Ч. Аналитическое решение задачи экранирования низкочастотного магнитного поля тонкими сферическими экранами / Г. Ч. Шушкевич // Информатика. – 2025. – Т. 22, № 3. – С. 59–71. – DOI: 10.37661/1816-0301-2025-22-3-59-71.

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Поступила в редакцию | Received 12.05.2025
Подписана в печать | Accepted 17.06.2025
Опубликована | Published 30.09.2025

Analytical solution of the shielding low-frequency magnetic field by thin spherical screens problem

Gennady Ch. Shushkevich

*Yanka Kupala State University of Grodno,
st. Ozheshko, 22, Grodno, 230023, Belarus
E-mail: gsys@grsu.by*

Abstract

Objectives. Construction of an analytical solution to the problem of shielding a low-frequency magnetic field by two thin non-intersecting spherical screens located on the surface of a sphere. Calculation of the shielding coefficient of the initial magnetic field by spherical screens.

Methods. The method of addition theorems and the method of triple summation equations are used to solve the boundary value problem. The potential of the initial magnetic field is represented as spherical harmonic functions. The secondary potentials of the magnetic field are represented as a superposition of spherical harmonic functions in a local coordinate system in three-dimensional space.

Results. The solution of the boundary value problem is reduced to the solution of a system of Fredholm integral equations of the second kind with respect to specially introduced functions. The influence of the geometric parameters of the problem on the value of the screening coefficient is numerically investigated. The results of the calculations are presented in the form of graphs.

Conclusion. The proposed methodology and the developed software can find practical application in the development and design of screens in various fields of technology.

Keywords: boundary value problem, magnetic field, potential, addition theorems, harmonic functions, triple series equations

Acknowledgements. The work was carried out within the framework of the "Mathematical Models and Methods" of the State Program for Scientific Research "Convergence 2025".

For citation. Shushkevich G. Ch. *Analytical solution of the shielding low-frequency magnetic field by thin spherical screens problem*. Informatika [Informatics], 2025, vol. 22, no. 3, pp. 59–71 (In Russ.). DOI: 10.37661/1816-0301-2025-22-3-59-71.

Conflict of interest. The author declares of no conflict of interest.

Введение. Компьютеры, мобильная телефонная связь, телевидение, интернет, бытовые электроприборы, электротранспорт и т. д. вызывают электромагнитное загрязнение окружающей среды. Надежным способом защиты от влияния электромагнитных полей различных устройств и других средств электромагнитного излучения как на биологические объекты, так и на чувствительные элементы электроники служит экранирование этих полей [1, 2]. Универсальными методами расчета электростатических, магнитных и электромагнитных полей являются численные методы: метод конечных разностей, метод конечных элементов и метод интегральных уравнений [3–5]. Однако актуальность разработки новых аналитических и численно-аналитических методов решения краевых задач математической физики не уменьшилась и в наши дни. Эти методы по-прежнему остаются основными средствами решения фундаментальных проблем, создают основу для тестирования решения краевых задач, полученных численными методами. Метод разделения переменных и аппарат функций комплексного переменного наиболее часто используются для аналитического решения граничных задач математической физики [6]. Обобщением метода разделения переменных для решения граничных задач со смешанными граничными условиями является метод парных (тройных) уравнений, позволяющий свести решение поставленной граничной задачи к решению интегрального уравнения Фредгольма второго рода, которое обычно не имеет аналитического решения в замкнутой форме, либо бесконечной системы линейных алгебраических уравнений второго рода. Этот метод применялся для решения электростатических задач для одиночных тонких незамкнутых оболочек [7–11].

При решении граничных задач математической физики для многосвязных областей успешно применялся метод теорем сложения [12–15]. Совместное использование теорем сложения и парных (тройных) уравнений позволило найти аналитическое решение задачи экранирования для двух и более экранов, представляющих собой как полные, так и неполные координатные поверхности [16–23].

В настоящей статье разработана методика аналитико-численного решения задачи экранирования низкочастотного магнитного поля двумя тонкими сферическими экранами, расположенным на сфере.

Постановка и представление решения задачи. Пусть в однородном и изотропном пространстве R^3 с магнитной проницаемостью среды μ находятся два идеально тонких сферических экрана S_0, S_1 , которые расположены на поверхности сферы Γ радиуса a с центром в точке O (рис. 1).

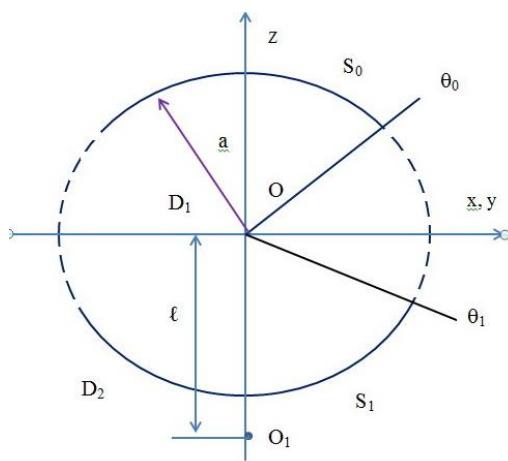


Рис. 1. Осевое сечение экранов
Fig. 1. Axial cross-section of shields

Для постановки граничной задачи в точке O введем декартовы координаты $Oxyz$. Декартовы координаты $Oxyz$ связаны со сферическими координатами $Or\theta\varphi$ соотношениями

$$x = r \sin \theta \cos \varphi, \quad y = r \sin \theta \sin \varphi, \quad z = r \cos \theta,$$

где $0 \leq r < \infty$, $0 \leq \theta \leq \pi$, $0 \leq \varphi \leq 2\pi$.

Тогда поверхности тонких сферических экранов S_0, S_1 описываются следующим образом:

$$S_0 = \{ r = a, 0 \leq \theta < \theta_0, 0 \leq \varphi \leq 2\pi \}, \quad S_1 = \{ r = a, \theta_1 < \theta \leq \pi, 0 \leq \varphi \leq 2\pi \}, \quad \theta_0 < \theta_1.$$

Разобьем все пространство R^3 поверхностью Γ на две области: $D_1(r < a)$ и $D_2(r > a)$.

Пусть в точке O_1 находится низкочастотный магнитный диполь, момент которого направлен вдоль оси Oz . Положим, что исходное низкочастотное электромагнитное поле изменяется во времени синусоидально, т. е. $\vec{\Phi}(M, t) = \{ \vec{E}(M), \vec{H}(M) \} \sin(\omega t)$, где $\vec{E}(M), \vec{H}(M)$ – напряженность электрического и магнитного полей соответственно, M – произвольная точка пространства, ω – угловая частота. В квазистационарном приближении система векторных уравнений Максвелла сводится к нахождению вторичного скалярного магнитного потенциала U_j ,

удовлетворяющего уравнению Лапласа $\Delta U_j = 0$, $j=1,2$, в области D_j [24]. Магнитный потенциал исходного поля U_i представим через сферические гармонические функции [12, 19, 22, 24]:

$$U_i(r_1, \theta_1) = P \left(\frac{\ell}{r_1} \right)^2 P_1(\cos \theta_1), \quad P = \frac{M_z}{4\pi\mu\ell^2}, \quad r_1 < \ell, \quad (1)$$

где M_z – магнитный момент, ℓ – расстояние между точками O и O_1 , $P_n(\cos \theta)$ – полиномы Лежандра [25].

Постановка задачи. Требуется найти вторичные потенциалы магнитного поля U_j , $j = 1, 2$, которые удовлетворяют:

- уравнению Лапласа

$$\Delta U_j = 0, \quad j = 1, 2,$$

где $\Delta = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} + \frac{\partial^2}{\partial z^2}$ – оператор Лапласа;

– граничным условиям на поверхностях сферических экранов S_0, S_1

$$\frac{\partial}{\partial \vec{n}} (U_i(M) + U_2(M)) \Big|_{M \in S_0} = 0, \quad (2)$$

$$\frac{\partial}{\partial \vec{n}} (U_i(M) + U_2(M)) \Big|_{M \in S_1} = 0, \quad (3)$$

где \vec{n} – нормаль к соответствующей поверхности;

– условию на бесконечности

$$U_2(M) \rightarrow 0 \text{ при } M \rightarrow \infty, \quad (4)$$

где M – произвольная точка области D_2 .

Кроме того, потребуем выполнения условия непрерывности потенциала на части поверхности сферы Γ , которая не является экраном, и условия непрерывности поля на поверхности сферы Γ :

$$(U_i(M) + U_2(M)) \Big|_{M \in \Gamma \setminus (S_0 \cup S_1)} = U_1(M) \Big|_{M \in \Gamma \setminus (S_0 \cup S_1)}, \quad (5)$$

$$\frac{\partial}{\partial \vec{n}} (U_i(M) + U_2(M)) \Big|_{M \in \Gamma} = \frac{\partial}{\partial \vec{n}} U_1(M) \Big|_{M \in \Gamma}. \quad (6)$$

Поставленная задача имеет единственное решение [26]. Физическая размерность потенциалов в системе СИ – A .

Согласно методу разделения переменных решение поставленной граничной задачи представим в виде суперпозиции сферических гармонических функций так, чтобы выполнялось условие на бесконечности (4):

$$U_1(r, \theta) = P \sum_{n=0}^{\infty} x_n \left(\frac{r}{a} \right)^n P_n(\cos \theta), \quad r < a, \quad (7)$$

$$U_2(r, \theta) = P \sum_{n=0}^{\infty} y_n \left(\frac{a}{r} \right)^{n+1} P_n(\cos \theta), \quad r > a. \quad (8)$$

Неизвестные коэффициенты x_n , y_n подлежат определению из граничных условий.

Выполнение граничных условий. Для выполнения граничных условий представим потенциал $U_i(r_1, \theta_1)$ через сферические гармонические функции в системе координат с началом в точке O . Для этого воспользуемся теоремой сложения (формулой), которая связывает сферические гармонические функции в системе координат с началом в точках O и O_1 [18, 27]:

$$r_1^{-n-1} P_n^m(\cos \theta_1) e^{im\phi} = \sum_{k=|m|}^{\infty} \frac{(-1)^{k+m} (n+k)!}{(n-m)! (k+m)!} \ell^{-k-n-1} r^k P_k^m(\cos \theta) e^{im\phi}, \quad r < \ell. \quad (9)$$

На основании формулы (9) потенциал исходного магнитного поля в сферической системе координат с началом в точке O имеет вид

$$U_i(r, \theta) = P \sum_{n=1}^{\infty} p_n \left(\frac{r}{\ell} \right)^n P_n(\cos \theta), \quad p_n = (-1)^n (n+1), \quad r < \ell. \quad (10)$$

С учетом представления потенциалов (7), (8), (10) условие непрерывности (6) в силу ортогональности полиномов Лежандра $P_n(\cos \theta)$ на отрезке $[0, \pi]$ эквивалентно соотношению

$$nx_n = -(n+1)y_n + np_n \left(\frac{a}{\ell} \right)^n, \quad n=1, 2, \dots . \quad (11)$$

Принимая во внимание представления потенциалов (7), (8), (10) и соотношение (11) и выполняя условия (2), (3), (5), получим тройные сумматорные уравнения по полиномам Лежандра

$$\begin{aligned} \sum_{n=0}^{\infty} (n+1) y_n P_n(\cos \theta) &= \sum_{n=0}^{\infty} n p_n \left(\frac{a}{\ell} \right)^n P_n(\cos \theta), \quad 0 \leq \theta < \theta_0, \\ \sum_{n=0}^{\infty} \left(y_n + p_n \left(\frac{a}{\ell} \right)^n - x_n \right) P_n(\cos \theta) &= 0, \quad \theta_0 < \theta < \theta_1, \\ \sum_{n=0}^{\infty} (n+1) y_n P_n(\cos \theta) &= \sum_{n=0}^{\infty} n p_n \left(\frac{a}{\ell} \right)^n P_n(\cos \theta), \quad \theta_1 < \theta \leq \pi. \end{aligned}$$

Введем в рассмотрение новые коэффициенты Y_n и малый параметр g_n по формулам

$$y_n = \frac{4n}{2n+1} Y_n, \quad g_n = \frac{1}{(2n+1)^2}, \quad n = 0, 1, 2, \dots . \quad (12)$$

Тогда вышеприведенные тройные сумматорные уравнения преобразуются к виду

$$\sum_{n=0}^{\infty} (2n+1) Y_n P_n(\cos \theta) = F(\theta), \quad 0 \leq \theta < \theta_0, \quad (13)$$

$$\sum_{n=0}^{\infty} Y_n P_n(\cos \theta) = 0, \quad \theta_0 < \theta < \theta_1, \quad (14)$$

$$\sum_{n=0}^{\infty} (2n+1) Y_n P_n(\cos \theta) = F(\theta), \quad \theta_1 < \theta \leq \pi, \quad (15)$$

где $F(\theta) = \sum_{n=0}^{\infty} (2n+1) \mathfrak{I}_n P_n(\cos \theta)$, $\mathfrak{I}_n = f_n + g_n Y_n = \frac{n}{2n+1} p_n \left(\frac{a}{\ell} \right)^n + g_n Y_n$.

Для решения тройных сумматорных уравнений (13)–(15) введем в рассмотрение две неизвестные функции $\varphi_1(t)$, $\varphi_2(t)$, $\varphi_1(t) \in C_{[0, \theta_0]}^{(1)}$, $\varphi_2(t) \in C_{[\theta_1, \pi]}^{(1)}$, удовлетворяющие условиям

$$\varphi_1(0) = \varphi_2(\pi) = 0 \quad (16)$$

и связанные с коэффициентами Y_n соотношением

$$Y_n = \int_0^{\theta_0} \varphi_1(t) \sin(n+0,5) t dt + \int_{\theta_1}^{\pi} \varphi_2(t) \cos(n+0,5) t dt. \quad (17)$$

Подставляя представление (17) в уравнение (14) и используя разложения разрывных функций в ряды по полиномам Лежандра [7, 18, 25]

$$\sum_{n=0}^{\infty} \sin\left(n + \frac{1}{2}\right) t P_n(\cos \theta) = \begin{cases} 0, & 0 \leq t < \theta < \pi, \\ \frac{1}{\sqrt{2(\cos \theta - \cos t)}}, & 0 < \theta < t \leq \pi, \end{cases} \quad (18)$$

$$\sum_{n=0}^{\infty} \cos\left(n + \frac{1}{2}\right) t P_n(\cos \theta) = \begin{cases} \frac{1}{\sqrt{2(\cos t - \cos \theta)}}, & 0 \leq t < \theta < \pi, \\ 0, & 0 < \theta < t \leq \pi, \end{cases} \quad (19)$$

убеждаемся, что это уравнение выполняется тождественно.

Подставим Y_n из соотношения (17) в уравнение (13) и проинтегрируем первый интеграл по частям:

$$\begin{aligned} -2\varphi_1(\theta_0) \sum_{n=0}^{\infty} \cos(n+0,5) \theta_0 P_n(\cos \theta) + 2 \int_0^{\theta_0} \varphi'_1(t) \left[\sum_{n=0}^{\infty} \cos(n+0,5) t P_n(\cos \theta) \right] dt + \\ + \int_{\theta_1}^{\pi} \varphi_2(t) \left[\sum_{n=0}^{\infty} (2n+1) \cos(n+0,5) t P_n(\cos \theta) \right] dt = F(\theta), \quad 0 \leq \theta < \theta_0. \end{aligned} \quad (20)$$

Согласно (19) первая сумма в уравнении (20) обращается в нуль, а вторая сумма преобразуется к виду

$$\int_0^{\theta_0} \varphi'_1(t) \left[\sum_{n=0}^{\infty} \cos(n+0,5) t P_n(\cos \theta) \right] dt = \int_0^{\theta_0} \frac{\varphi'_1(t) dt}{\sqrt{2(\cos t - \cos \theta)}}.$$

Используя разложение (18), третье выражение в (20) представим в виде

$$\begin{aligned} \int_{\theta_1}^{\pi} \varphi_2(t) \left[\sum_{n=0}^{\infty} (2n+1) \cos(n+0,5)t P_n(\cos \theta) \right] dt &= 2 \int_{\theta_1}^{\pi} \varphi_2(t) \frac{d}{dt} \left(\frac{1}{\sqrt{2(\cos \theta - \cos t)}} \right) dt = \\ &= -2 \int_{\theta_1}^{\pi} \frac{\varphi_2(t) \sin t dt}{\sqrt{(2(\cos \theta - \cos t))^3}}. \end{aligned}$$

На основании выполненных преобразований уравнение (20) примет вид

$$\int_0^{\theta} \frac{\varphi_1'(t) dt}{\sqrt{2(\cos t - \cos \theta)}} = V(\theta), \quad (21)$$

где

$$V(\theta) = 0,5F(\theta) + \int_{\theta_1}^{\pi} \frac{\varphi_2(t) \sin t dt}{\sqrt{(2(\cos \theta - \cos t))^3}}. \quad (22)$$

Уравнение (21) является интегральным уравнением Абеля. На основании его решения [7] имеем

$$\varphi_1'(t) = \frac{2}{\pi} \frac{d}{dt} \int_0^t \frac{V(\theta) \sin \theta d\theta}{\sqrt{2(\cos \theta - \cos t)}}.$$

Проинтегрируем полученное выражение и с учетом (16) получим уравнение

$$\varphi_1(t) = \frac{2}{\pi} \int_0^t \frac{V(\theta) \sin \theta d\theta}{\sqrt{2(\cos \theta - \cos t)}}. \quad (23)$$

Преобразуем правую часть (23). Принимая во внимание представление (22), получим

$$\begin{aligned} \frac{2}{\pi} \int_0^t \frac{V(\theta) \sin \theta d\theta}{\sqrt{2(\cos \theta - \cos t)}} &= \frac{1}{\pi} \sum_{n=0}^{\infty} (2n+1) \Im_n \int_0^t \frac{P_n(\cos \theta) \sin \theta d\theta}{\sqrt{2(\cos \theta - \cos t)}} + \\ &+ \frac{1}{2\pi} \int_{\theta_1}^{\pi} \varphi_2(\tau) \left[\sin \tau \int_0^t \frac{\sin \theta d\theta}{(\cos \theta - \cos \tau)^{3/2} (\cos \theta - \cos t)^{1/2}} \right] d\tau. \end{aligned}$$

Учитывая интегралы [7, 18, 25]

$$\int_0^x \frac{P_n(\cos \theta) \sin \theta d\theta}{\sqrt{2(\cos \theta - \cos x)}} = \frac{\sin(n+0,5)x}{n+0,5},$$

$$\sin \tau \int_0^t \frac{\sin \theta d\theta}{(\cos \theta - \cos \tau)^{3/2} (\cos \theta - \cos t)^{1/2}} = -\cos ec((t+\tau)/2) - \cos ec((t-\tau)/2),$$

уравнение (23) преобразуем к интегральному уравнению вида

$$\varphi_1(t) + \int_{\theta_1}^{\pi} K_1(t, \tau) \varphi_2(\tau) d\tau = \frac{2}{\pi} \sum_{n=0}^{\infty} \mathfrak{I}_n \sin(n+0,5)t, \quad 0 \leq t < \theta_0, \quad (24)$$

где ядро интегрального уравнения

$$K_1(t, \tau) = \frac{1}{2\pi} [\csc((t+\tau)/2) + \csc((t-\tau)/2)].$$

Проводя аналогичные преобразования, получим, что уравнение (15) преобразуется к интегральному уравнению вида

$$\varphi_2(t) + \int_0^{\theta_0} K_2(t, \tau) \varphi_1(\tau) d\tau = \frac{2}{\pi} \sum_{n=0}^{\infty} \mathfrak{I}_n \cos(n+0,5)t, \quad \theta_1 < t \leq \pi, \quad (25)$$

где

$$K_2(t, \tau) = \frac{1}{2\pi} [\csc((t+\tau)/2) - \csc((t-\tau)/2)].$$

На основании представления коэффициента \mathfrak{I}_n из уравнений (24), (25) получим связанную систему интегральных уравнений Фредгольма второго рода относительно функций $\varphi_1(t)$, $\varphi_2(t)$:

$$\begin{aligned} \varphi_1(t) &= \int_0^{\theta_0} L_1(t, \tau) \varphi_1(\tau) d\tau + \int_{\theta_1}^{\pi} (L_2(t, \tau) - K_1(t, \tau)) \varphi_2(\tau) d\tau = \frac{2}{\pi} \sum_{n=0}^{\infty} f_n \sin(n+0,5)t, \quad 0 \leq t < \theta_0, \\ \varphi_2(t) &= \int_0^{\theta_0} (L_2(\tau, t) - K_2(t, \tau)) \varphi_1(\tau) d\tau + \int_{\theta_1}^{\pi} L_3(t, \tau) \varphi_2(\tau) d\tau = \frac{2}{\pi} \sum_{n=0}^{\infty} f_n \cos(n+0,5)t, \quad \theta_1 < t \leq \pi, \end{aligned} \quad (26)$$

где

$$\begin{aligned} L_1(t, \tau) &= \frac{2}{\pi} \sum_{n=0}^{\infty} g_n \sin(n+0,5)t \sin(n+0,5)\tau, \quad L_2(t, \tau) = \frac{2}{\pi} \sum_{n=0}^{\infty} g_n \sin(n+0,5)t \cos(n+0,5)\tau, \\ L_3(t, \tau) &= \frac{2}{\pi} \sum_{n=0}^{\infty} g_n \cos(n+0,5)t \cos(n+0,5)\tau, \quad f_n = (-1)^n \frac{n(n+1)}{2n+1} \left(\frac{a}{\ell} \right)^n. \end{aligned}$$

Вычисление коэффициента экранирования. Коэффициент экранирования (ослабления) магнитного поля в области D_1 вычислим по формуле

$$K(r, \theta) = |\vec{H}_1(r, \theta)| / |\vec{H}_i(r, \theta)|, \quad r < a,$$

где $\vec{H}_1(r, \theta)$ – напряженность вторичного магнитного поля в области D_1 :

$$\vec{H}_1(r, \theta) = -\operatorname{grad} u_1(r, \theta) = -\left(\frac{\partial}{\partial r} u_1(r, \theta) \vec{e}_r + \frac{1}{r} \frac{\partial}{\partial \theta} u_1(r, \theta) \vec{e}_{\theta} \right),$$

$\vec{H}_i(r, \theta)$ – напряженность первичного магнитного поля в области D_1 :

$$\vec{H}_i(r, \theta) = -\text{grad } u_i(r, \theta) = -\left(\frac{\partial}{\partial r} u_i(r, \theta) \vec{e}_r + \frac{1}{r} \frac{\partial}{\partial \theta} u_i(r, \theta) \vec{e}_\theta \right).$$

Из формул (7), (10) и производной $\frac{d}{d\theta} P_n(\cos \theta) = P_n^1(\cos \theta)$, где $P_n^1(\cos \theta)$ – присоединенная функция Лежандра [25], следуют равенства

$$\begin{aligned} \frac{\partial}{\partial r} u_i(r, \theta) &= P \sum_{n=1}^{\infty} n x_n \frac{r^{n-1}}{a^n} P_n(\cos \theta), & \frac{\partial}{\partial \theta} u_i(r, \theta) &= P \sum_{n=1}^{\infty} x_n \frac{r^n}{a^n} P_n^1(\cos \theta), \\ \frac{\partial}{\partial r} u_i(r, \theta) &= P \sum_{n=1}^{\infty} n p_n \frac{r^{n-1}}{\ell^n} P_n(\cos \theta), & \frac{\partial}{\partial \theta} u_i(r, \theta) &= P \sum_{n=1}^{\infty} p_n \frac{r^n}{\ell^n} P_n^1(\cos \theta). \end{aligned}$$

Для численного решения системы интегральных уравнений Фредгольма второго рода (26) использована обобщенная квадратурная формула Симпсона, которая имеет четвертый порядок точности [28]. Все сходящиеся бесконечные суммы вычислены с точностью 0,001.

Приведем некоторые результаты расчетов. Пусть геометрические параметры задачи $\ell/a = 3$. На рис. 2, a показаны графики коэффициента экранирования $K(r, \theta)$ в области D_1 при $\theta_0 = 90^\circ$, $\theta_1 = 170^\circ$ и некоторых значениях r/a (значения приведены в левом углу рисунка), а на рис. 2, b – при $\theta_0 = 90^\circ$, $\theta_1 = 135^\circ$ (увеличен угол раствора сферического экрана S_1).

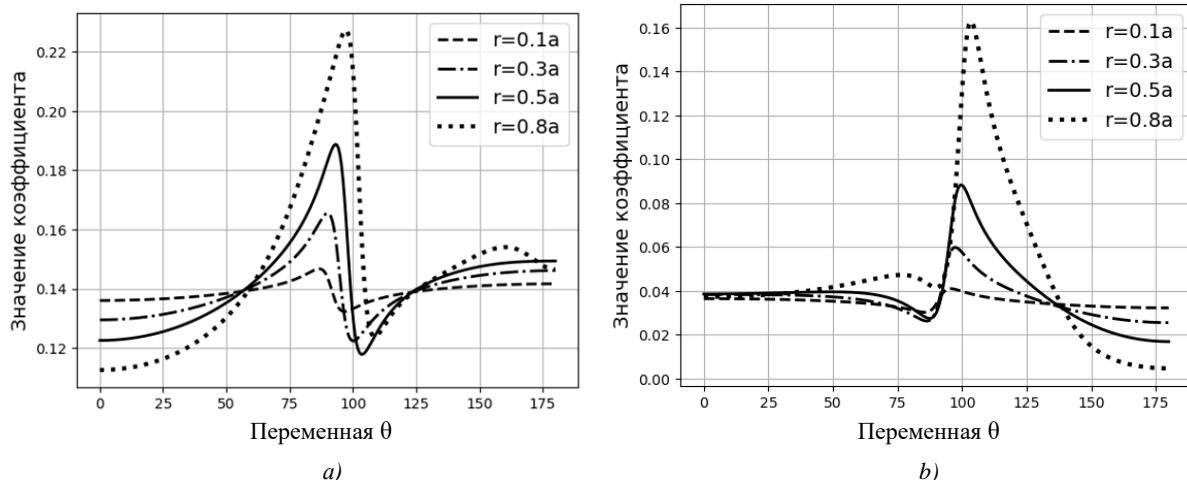


Рис. 2. Графики коэффициента экранирования $K(r, \theta)$, $r < a$: a) при $\theta_0 = 90^\circ$, $\theta_1 = 170^\circ$; b) при $\theta_0 = 90^\circ$, $\theta_1 = 135^\circ$

Fig. 2. Graphs of the shielding coefficient $K(r, \theta)$, $r < a$: a) at $\theta_0 = 90^\circ$, $\theta_1 = 170^\circ$; b) at $\theta_0 = 90^\circ$, $\theta_1 = 135^\circ$

При увеличении угла раствора сферического экрана S_1 значение $K(r, \theta)$, $r < a$, уменьшается (рис. 2, b).

На рис. 3, a изображены графики коэффициента экранирования $K(r, \theta)$ в области D_1 при $\theta_0 = 30^\circ$, $\theta_1 = 150^\circ$ и некоторых значениях r/a (значения приведены в левом углу рисунка), а на рис. 3, b – при $\theta_0 = 130^\circ$, $\theta_1 = 150^\circ$ (увеличен угол раствора сферического экрана S_0).

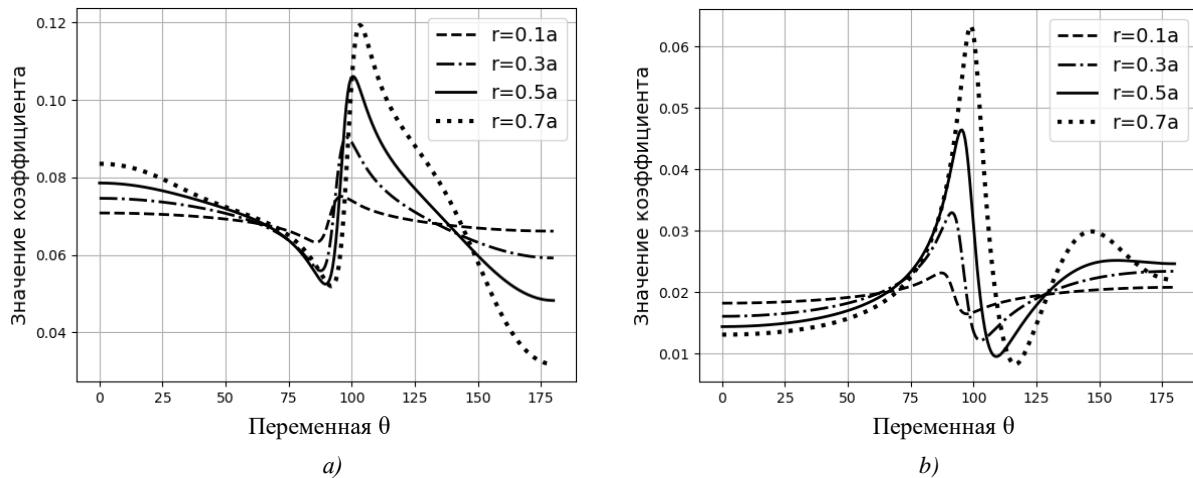


Рис. 3. Графики коэффициента экранирования $K(r,\theta)$, $r < a$: а) при $\theta_0 = 30^\circ$, $\theta_1 = 150^\circ$; б) при $\theta_0 = 130^\circ$, $\theta_1 = 150^\circ$

Fig. 3. Graphs of the shielding coefficient $K(r,\theta)$, $r < a$: a) at $\theta_0 = 30^\circ$, $\theta_1 = 150^\circ$; b) at $\theta_0 = 130^\circ$, $\theta_1 = 150^\circ$

При увеличении угла раствора сферического экрана S_0 значение коэффициента экранирования $K(r,\theta)$, $r < a$, уменьшается. Магнитное поле практически не проникает в область D_1 при $\theta_0 = 130^\circ$, $\theta_1 = 150^\circ$.

Заключение. В статье разработана методика аналитико-численного решения задачи экранирования низкочастотного магнитного поля двумя тонкими непересекающимися сферическими экранами, расположенными на поверхности сферы. Источником поля является низкочастотный магнитный диполь. Решение поставленной граничной задачи сведено к решению системы интегральных уравнений Фредгольма второго рода относительно специальным образом введенных функций. Численно исследовано влияние геометрических параметров задачи на значение коэффициента экранирования. Результаты вычислений представлены в виде графиков. Разработанные методика и программное обеспечение могут найти практическое применение при конструировании экранов в различных областях техники.

Список использованных источников

1. Шапиро, Д. Н. Электромагнитное экранирование / Д. Н. Шапиро. – Долгопрудный : Издательский дом «Интеллект», 2010. – 120 с.
2. Кечиев, Л. Н. Экранирование радиоэлектронной аппаратуры. Инженерное пособие / Л. Н. Кечиев. – М. : Грифон, 2019. – 720 с.
3. Дмитриев, В. И. Метод интегральных уравнений в вычислительной электродинамике / В. И. Дмитриев, Е. В. Захаров. – М. : МАКС Пресс, 2008. – 316 с.
4. Ильин, В. П. Методы конечных разностей и конечных объемов для эллиптических уравнений / В. П. Ильин. – Новосибирск : Изд-во Ин-та математики, 2000. – 345 с.
5. Исаев, Ю. Н. Методы расчета электромагнитных полей. Практика использования MathCAD, COMSOL Multiphysics / Ю. Н. Исаев, О. В. Васильева. – Saarbrucken : LAP LAMBERT Academic Publishing, 2012. – 162 с.
6. Pierrus, J. Solved Problems in Classical Electromagnetism: Analytical and Numerical Solutions with Comments / J. Pierrus. – Oxford : Oxford University Press, 2018. – 638 p. – DOI: 10.1093/oso/9780198821915.001.0001.
7. Уфлянд, Я. С. Метод парных уравнений в задачах математической физики / Я. С. Уфлянд. – М. : Наука, 1977. – 220 с.
8. Шестопалов, В. П. Сумматорные уравнения в современной теории дифракции / В. П. Шестопалов. – Киев : Наукова думка, 1983. – 252 с.
9. Boridy, E. Quasistatic magnetic field penetration through a circular aperture of a spherical shield enclosing a spherical conductor / E. Boridy // Journal of Applied Physics. – 1990. – Vol. 68, no. 2. – P. 422–430.

10. Duffy, D. G. Mixed boundary value problems / D. G. Duffy. – N. Y. : Chapman & Hall/CRC, 2008. – 488 p. – DOI: 10.1201/9781420010947.
11. Шушкевич, Г. Ч. Методика решения электростатической задачи для тонкой незамкнутой сферической оболочки / Г. Ч. Шушкевич // Электричество. – 2010. – № 6. – С. 63–68.
12. Иванов, Е. А. Дифракция электромагнитных волн на двух телах / Е. А. Иванов. – Минск : Наука и техника, 1968. – 584 с.
13. Ерофеенко, В. Т. Задача электростатики для двух тороидальных проводников / В. Т. Ерофеенко // Журнал технической физики. – 1986. – Т. 56, № 8. – С. 1641–1643.
14. Shushkevich, G. Ch. Electrostatic problem for a torus placed in an infinite cylinder / G. Ch. Shushkevich // Technical Physics. – 2004. – Vol. 49, no. 5. – P. 540–544.
15. Шушкевич, Г. Ч. Проникновение низкочастотного магнитного поля через плоский слой со сфероидальным включением, тонкостенными слоями / Г. Ч. Шушкевич, А. И. Куц // Веснік Гродзенскага дзяржаўнага ўніверсітэта. Сер. 2. Матэматыка. Фізіка. Інфарматыка, вылічальная тэхніка і кіраванне. – 2012. – № 3. – С. 45–52.
16. Shushkevich, G. Ch. Electrostatic field of a flattened ellipsoid and disc between two thin open spherical shells / G. Ch. Shushkevich, S. V. Shushkevich // Electrical Technology. – 1996. – no. 1. – P. 89–99.
17. Shushkevich, G. Ch. Electrostatic problem for a torus and a disk / G. Ch. Shushkevich // Technical Physics. – 1997. – Vol. 42, no. 4. – P. 436–438.
18. Шушкевич, Г. Ч. Моделирование полей в многосвязных областях в задачах электростатики / Г. Ч. Шушкевич. – Saarbruchen : LAP LAMBERT Academic Publishing, 2015. – 228 с.
19. Erofeenko, V. T. Screening of low-frequency magnetic fields by an open thin-wall spherical shell / V. T. Erofeenko, I. S. Kozlovskaya, G. Ch. Shushkevich // Technical Physics. – 2010. – Vol. 55, no. 9. – P. 1240–1247. – DOI: 10.1134/S1063784210090021.
20. Erofeenko, V. T. Shielding of a low-frequency electric field by a multilayer circular disk / V. T. Erofeenko, G. H. Shushkevich // Technical Physics. – 2013. – Vol. 58, no. 6. – P. 866–871. – DOI: 10.1134/S106378421306011X.
21. Шушкевич, Г. Ч. Аналитическое решение задачи экранирования низкочастотного магнитного поля тонкостенным цилиндрическим экраном в присутствии цилиндра / Г. Ч. Шушкевич // Информатика. – 2021. – Т. 18, № 3. – С. 45–55.
22. Шушкевич, Г. Ч. Аналитическое решение задачи экранирования низкочастотного магнитного поля двумя тонкостенными цилиндрическими экранами / Г. Ч. Шушкевич // Веснік Гродзенскага дзяржаўнага ўніверсітэта імя Янкі Купалы. Сер. 2. Матэматыка. Фізіка. Інфарматыка, вылічальная тэхніка і кіраванне. – 2022. – Т. 12, № 1. – С. 16–24.
23. Шушкевич, Г. Ч. Аналитическое решение задачи экранирования низкочастотного магнитного поля тонкостенным цилиндрическим экраном с эллипсоидальным включением / Г. Ч. Шушкевич // Веснік Гродзенскага дзяржаўнага ўніверсітэта імя Янкі Купалы. Сер. 2. Матэматыка. Фізіка. Інфарматыка, вылічальная тэхніка і кіраванне. – 2024. – Т. 14, № 3. – С. 80–89.
24. Аполлонский, С. М. Моделирование и расчет электромагнитных полей в технических устройствах : в 3 т. / С. М. Аполлонский. – М. : Русайнс, 2024. – Т. 3: Расчеты электромагнитных полей в научных и инженерно-технических задачах. – 388 с.
25. Справочник по специальным функциям с формулами, графиками и таблицами : пер. с англ. / под ред. М. Абрамовича, И. Стиган. – М. : Наука, 1979. – 830 с.
26. Корзюк, В. И. О разрешимости некоторых задач в теории экранирования полей системами экранов / В. И Корзюк, Г. Ч. Шушкевич // Труды Института математики НАН Беларуси. – 2006. – Т. 14, № 1. – С. 71–81.
27. Ерофеенко, В. Т. Теоремы сложения / В. Т. Ерофеенко. – Минск : Наука и техника, 1989. – 240 с.
28. Вержбицкий, В. М. Основы численных методов / В. М. Вержбицкий. – М. : Высшая школа, 2002. – 848 с.

References

1. Shapiro D. N. Elektromagnitnoye ekranirovaniye. *Electromagnetic Shielding*. Dolgoprudny, Izdatel'skij dom "Intellekt", 2010, 120 p. (In Russ.).
2. Kechiev L. N. Ekranirovaniye radioelektronnoy apparatury. Inzhenernoye posobiye. *Shielding of Electronic Equipment. Engineering Manual*. Moscow, Grifon, 2019, 720 p. (In Russ.).
3. Dmitriev V. I., Zakharov E. V. Metod integral'nykh uravneniy v vychislitel'noy elektrodinamike. *Method of Integral Equations in Computational Electrodynamics*. Moscow, MAKS Press, 2008, 316 p. (In Russ.).

4. Ilyin V. P. Metody konechnykh raznostei i konechnykh ob"emov dlia ellipticheskikh uravnenii. *Finite Difference and Finite Volume Methods for Elliptic Equations*. Novosibirsk, Izdatel'stvo Instituta matematiki, 2000, 345 p. (In Russ.).
5. Isaev Yu. N., Vasilyeva O. V. Metody rascheta elektromagnitnykh poley. Praktika ispol'zovaniya MathCAD, COMSOL Multiphysics. *Methods for the Calculation of Electromagnetic Fields. Practice Using MathCAD, COMSOL Multiphysics*. Saarbruchen, LAP LAMBERT Academic Publishing, 2012, 162 p. (In Russ.).
6. Pierrus J. *Solved Problems in Classical Electromagnetism: Analytical and Numerical Solutions with Comments*. Oxford, Oxford University Press, 2018, 638 p. DOI: 10.1093/oso/9780198821915.001.0001.
7. Uflyand Ya. S. Metod parnykh uravneniy v zadachakh matematicheskoy fiziki. *Method of Paired Equations in Problems of Mathematical Physics*. Moscow, Nauka, 1977, 220 p.
8. Shestopalov V. P. Summatornyye uravneniya v sovremennoy teorii difraktsii. *Summation Equations in Modern Diffraction Theory*. Kyiv, Naukova dumka, 1983, 252 p. (In Russ.).
9. Boridy E. Quasistatic magnetic field penetration through a circular aperture of a spherical shield enclosing a spherical conductor. *Journal of Applied Physics*, 1990, vol. 68, no. 2, pp. 422–430.
10. Duffy D. G. *Mixed Boundary Value Problems*. New York, Chapman & Hall/CRC, 2008, 488 p. DOI: 10.1201/9781420010947.
11. Shushkevich G. Ch. A technique for solving an electrostatic problem for a thin non-closed spherical shell. *Elektrichestvo [Electricity]*, 2010, no. 6, pp. 63–68 (In Russ.).
12. Ivanov E. A. Difraktsiya elektromagnitnykh voln na dvukh telakh. *Diffraction of Electromagnetic Waves on Two Bodies*. Minsk, Nauka i tekhnika, 1968, 584 p. (In Russ.).
13. Erofeenko V. T. The problem of electrostatics for two toroidal conductors. *Zhurnal tekhnicheskoy fiziki [Journal of Technical Physics]*, 1986, vol. 56, no. 8, pp. 1641–1643 (In Russ.).
14. Shushkevich G. Ch. Electrostatic problem for a torus placed in an infinite cylinder. *Technical Physics*, 2004, vol. 49, no. 5, pp. 540–544.
15. Shushkevich G. Ch., Kuts A. I. Penetration of a low-frequency magnetic field through a flat layer with a spheroidal inclusion, thin-walled layers. *Vesnik Grodzenskogo gosudarstvennogo universiteta. Ser. 2. Matematika. Fizika. Infarmatyka, vychisl'naya tekhnika i kiravanne [Bulletin of Grodno State University. Ser. 2. Mathematics. Physics. Informatics, Computer Engineering and Management]*, 2012, no. 3, pp. 45–52 (In Russ.).
16. Shushkevich, G. Ch., Shushkevich S. V. Electrostatic field of a flattened ellipsoid and disc between two thin open spherical shells. *Electrical Technology*, 1996, no. 1, pp. 89–99.
17. Shushkevich, G. Ch. Electrostatic problem for a torus and a disk. *Technical Physics*, 1997, vol. 42, no. 4, pp. 436–438.
18. Shushkevich G. Ch. Modelirovanie polei v mnogosvyaznykh oblastyakh v zadachakh elektrostatiki. *Modeling Fields in Multiply Connected Domains in Electrostatic Problems*. Saarbruchen, LAP LAMBERT Academic Publishing, 2015, 228 p. (In Russ.).
19. Erofeenko V. T., Kozlovskaya I. S., Shushkevich G. Ch. Screening of low-frequency magnetic fields by an open thin-wall spherical shell. *Technical Physics*, 2010, vol. 55, no. 9, pp. 1240–1247. DOI: 10.1134/S1063784210090021.
20. Erofeenko V. T., Shushkevich G. H. Shielding of a low-frequency electric field by a multilayer circular disk. *Technical Physics*, 2013, vol. 58, no. 6, pp. 866–871. DOI: 10.1134/S106378421306011X.
21. Shushkevich G. Ch. Analytical solution to the problem of shielding a low-frequency magnetic field with a thin-walled cylindrical screen in the presence of a cylinder. *Informatika [Informatics]*, 2021, vol. 18, no. 3, pp. 45–55 (In Russ.).
22. Shushkevich G. Ch. Analytical solution to the problem of shielding a low-frequency magnetic field with two thin-walled cylindrical screens. *Vesnik Grodzenskogo gosudarstvennogo universiteta. Ser. 2. Matematika. Fizika. Infarmatyka, vychisl'naya tekhnika i kiravanne [Bulletin of Grodno State University. Ser. 2. Mathematics. Physics. Informatics, Computer Engineering and Management]*, 2022, vol. 12, no. 1, pp. 16–24 (In Russ.).
23. Shushkevich G. Ch. Analytical solution to the problem of shielding a low-frequency magnetic field with a thin-walled cylindrical screen with an ellipsoidal inclusion. *Vesnik Grodzenskogo gosudarstvennogo universiteta. Ser. 2. Matematika. Fizika. Infarmatyka, vychisl'naya tekhnika i kiravanne [Bulletin of Grodno State University. Ser. 2. Mathematics. Physics. Informatics, Computer Engineering and Management]*, 2024, vol. 14, no. 3, pp. 80–89 (In Russ.).
24. Apollonsky S. M. Modelirovaniye i raschet elektromagnitnykh poley v tekhnicheskikh ustroystvakh [Modeling and Calculation of Electromagnetic Fields in Technical Devices]. T. 3. Raschety elektromagnitnykh poley v nauchnykh i inzhenerno-tehnicheskikh zadachakh [Vol. 3. Calculations of Electromagnetic Fields in Scientific and Engineering Problems]. Moscow, Rusajns, 2024, 388 p. (In Russ.).
25. Abramowitz M., Stegun I. A. (eds.). *Handbook of Mathematical Functions: with Formulas, Graphs, and Mathematical Tables*. Dover Publications, 1965, 1046 p.

26. Korzyuk V. I., Shushkevich G. Ch. *On the solvability of some problems in the theory of screening of fields by systems of screens.* Trudy Instituta matematiki NAN Belarusi [Proceedings of the Institute of Mathematics of the NAS of Belarus], 2006, vol. 14, no. 1, pp. 71–81 (In Russ.).
27. Erofeenko V. T. Teoremy slozheniya. *Addition Theorems.* Minsk, Nauka i tekhnika, 1989, 240 p. (In Russ.).
28. Verzhbitsky V. M. Osnovy chislennykh metodov. *Fundamentals of Numerical Methods.* Moscow, Vysshaya shkola, 2002, 848 p. (In Russ.).

Информация об авторе

Шушкевич Геннадий Чеславович, доктор физико-математических наук, профессор кафедры современных технологий программирования, Гродненский государственный университет им. Янки Купалы.
E-mail: gsys@grsu.by

Information about the author

Gennady Ch. Shushkevich, D. Sc. (Phys.-Math.), Prof. of Modern Programming Technologies Department, Yanka Kupala State University of Grodno.
E-mail: gsys@grsu.by

ЗАЩИТА ИНФОРМАЦИИ И НАДЕЖНОСТЬ СИСТЕМ

INFORMATION PROTECTION AND SYSTEM RELIABILITY



УДК 004.056.5
DOI: 10.37661/1816-0301-2025-22-3-72-82

Оригинальная статья
Original Article

Аппроксимация двоичных функций на основе двухслойной искусственной нейронной сети

К. В. Латушкин, Ю. С. Харин[✉]

НИИ прикладных проблем математики и информатики
Белорусского государственного университета,
пр. Независимости, 4, Минск, 220030, Беларусь
[✉]E-mail: Kharin@bsu.by

Аннотация

Цели. Рассматриваются особенности применения двухслойных искусственных нейронных сетей в задачах аппроксимации двоичных функций многих двоичных переменных. Изучаются вопросы выбора начальных значений весов модели и количества нейронов на скрытом слое.

Методы. Задача аппроксимации двоичной функции с помощью искусственной нейронной сети сводится к геометрической задаче разделения вершин многомерного куба гиперплоскостями. Комбинаторными методами доказываются леммы о способах разбиения гиперкуба гиперплоскостью и строится оценка снизу количества двоичных функций, для аппроксимации которых достаточно один нейрон на скрытом слое.

Результаты. Рассмотрены особенности задания начальных значений весов искусственной нейронной сети. Построена оценка снизу числа двоичных функций, для аппроксимации которых достаточно искусственной нейронной сети с одним нейроном на скрытом слое. Найдена алгоритмическая сложность вычисления такой оценки. Представлены численные результаты применения двухслойных искусственных нейронных сетей для аппроксимации двоичных функций в задачах защиты информации.

Заключение. Результаты статьи позволяют выбирать параметры искусственной нейронной сети для повышения точности аппроксимации двоичных функций многих переменных.

Ключевые слова: двоичная функция, комбинаторика, искусственная нейронная сеть, аппроксимация функций, генераторы псевдослучайных последовательностей

Для цитирования. Латушкин, К. В. Аппроксимация двоичных функций на основе двухслойной искусственной нейронной сети / К. В. Латушкин, Ю. С. Харин // Информатика. – 2025. – Т. 22, № 3. – С. 72–82. – DOI: 10.37661/1816-0301-2025-22-3-72-82.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 16.07.2025
Подписана в печать | Accepted 18.08.2025
Опубликована | Published 30.09.2025

Approximation of binary functions based on two-layer artificial neural network

Konstantin V. Latushkin, Yuriy S. Kharin[✉]

Research Institute of Applied Problems of Mathematics
and Informatics of the Belarusian State University,
av. Nezavisimosti, 4, Minsk, 220030, Belarus

[✉]E-mail: Kharin@bsu.by

Abstract

Objectives. The article examines the features of using two-layer artificial neural network in problems of approximating binary functions of many binary variables. The issues of choosing the initial values of the model weights and choosing the number of neurons on the hidden layer are studied.

Methods. The problem of approximating a binary function using an artificial neural network is reduced to the geometric problem of dividing the vertices of a multidimensional cube by hyperplanes. Combinatorial methods are used to prove lemmas on ways of dividing a hypercube by a hyperplane and to construct a lower estimate for the number of binary functions that can be approximated using one neuron on the hidden layer.

Results. The features of setting the initial values of weights of an artificial neural network are considered. A lower bound is constructed for the number of binary functions that can be approximated using an artificial neural network with one neuron on the hidden layer. The algorithmic complexity of calculating such an estimate is found. Numerical results are presented for using two-layer artificial neural networks to approximate binary functions in information security problems.

Conclusion. The results of the article allow choosing the parameters of an artificial neural network to improve the accuracy of approximation of binary functions of many variables.

Keywords: binary functions, combinatorics, artificial neural network, function approximation, pseudorandom sequence generators

For citation. Latushkin K. V., Kharin Yu. S. *Approximation of binary functions based on two-layer artificial neural network*. Informatika [Informatics], 2025, vol. 22, no. 3, pp. 72–82 (In Russ.). DOI: 10.37661/1816-0301-2025-22-3-72-82.

Conflict of interest. The authors declare of no conflict of interest.

Введение. В последние годы искусственные нейронные сети (ИНС) начинают широко применяться в задачах анализа дискретных, в том числе двоичных, данных в криптологии и кибербезопасности [1–4]. Примерами таких задач являются: двоичная классификация по наблюдениям, представляемым двоичными векторами; аппроксимация двоичных функций в программных датчиках псевдослучайных последовательностей; оценка сложности s -блоков в криптографических системах; распознавание наличия компьютерной атаки на информационные системы. Математически эти задачи сводятся к задаче аппроксимации двоичных функций от многих двоичных переменных. Исследованию особенностей этой актуальной задачи посвящена данная статья.

Математическая модель и постановка задачи. Введем обозначения: $V = \{0,1\}$ – двоичный алфавит; s – натуральное число; V^s – s -мерный двоичный гиперкуб; $x = (x_1, x_2, \dots, x_s)' \in V^s$ – двоичный вектор-столбец, или, в геометрической интерпретации, некоторая вершина гиперкуба V^s ; $1\{B\} \in V$ – индикатор события B , $1\{B\} = \{1, \text{ если } B \text{ справедливо}; 0 \text{ в противном случае}\}$.

Пусть на множестве V^s определена некоторая неизвестная двоичная функция s двоичных переменных:

$$y = f(x) = f(x_1, x_2, \dots, x_s), x \in V^s, y \in V. \quad (1)$$

В геометрической интерпретации функция (1) задает классификацию (разбиение) вершин гиперкуба V^s на два непересекающихся класса: $\Omega_0 = \{x \in V^s : f(x) = 0\}$ и $\Omega_1 = \{x \in V^s : f(x) = 1\}$: $V^s = \Omega_0 \cup \Omega_1$, $\Omega_0 \cap \Omega_1 = \emptyset$. Функцию (1) можно также интерпретировать как раскраску каждой вершины $x \in V^s$ гиперкуба в один из двух цветов: $y = 0$ или $y = 1$. Обозначим \mathcal{F} – множество всевозможных двоичных функций от s двоичных переменных, $|\mathcal{F}| = K = 2^{2^s}$.

Рассмотрим задачу аппроксимации (восстановления) функции (1) по случайной выборке объемом n из V^s : $X = \{x^{(1)}, x^{(2)}, \dots, x^{(n)}\} \subseteq V^s$ и известным значениям $y^{(t)} = f(x^{(t)})$, $t = 1, \dots, n$. Для решения этой задачи используется двухслойная ИНС (с s входами, одним скрытым слоем с m нейронами и одним выходом), проиллюстрированная на рис. 1, где $H_l^{(1)}$ – l -й нейрон скрытого слоя, m – число нейронов, $H^{(2)}$ – выходной нейрон ИНС.

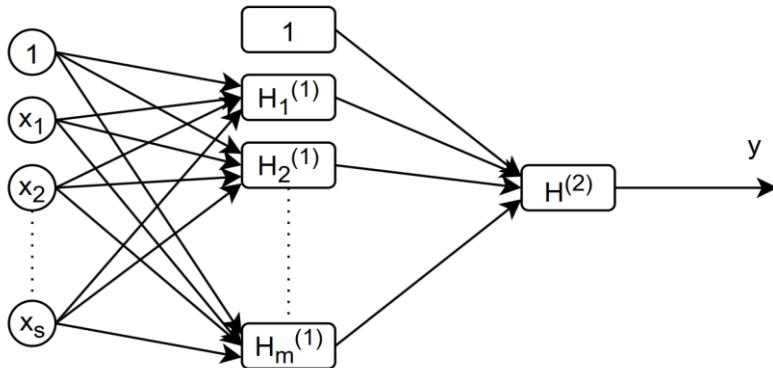


Рис. 1. Схема ИНС

Fig. 1. ANN diagram

ИНС на рис. 1 определяет аппроксимирующую для $f(\cdot)$ функцию $\hat{f}(x) = \hat{f}(x_1, x_2, \dots, x_s) \in V$ с $m(s+2)+1$ оцениваемыми по выборке X параметрами:

$$\hat{f}(x_1, \dots, x_s) = \sigma \left(b_0 + \sum_{l=1}^m b_l \cdot \text{ReLU} \left(a_{0l} + \sum_{i=1}^s a_{il} x_i \right) \right), \quad (2)$$

где m – натуральное число (число нейронов на скрытом слое); $\{a_{il}\}, \{b_l\}$ – параметры (коэффициенты, веса) модели; $\text{ReLU}(z) = \max\{0, z\}$, $\sigma(z) = (1 + e^{-z})^{-1}$ – так называемые функции активации [5].

Отметим, что ИНС с одним скрытым слоем выбирается авторами с целью выявления математических особенностей аппроксимации двоичных функций, которые в дальнейшем могут обобщаться на многослойные ИНС.

Аппроксимация $f(\cdot)$ с помощью $\hat{f}(\cdot)$ получается как результат процесса обучения ИНС (2), заключающегося в минимизации функции потерь по $\{a_{il}\}, \{b_l\}$:

$$h(\hat{y}) = -\frac{1}{n} \sum_{t=1}^n (y^{(t)} \log(\hat{y}^{(t)}) + (1 - y^{(t)}) \log(1 - \hat{y}^{(t)})) \rightarrow \min_{\{a_{il}\}, \{b_l\}}. \quad (3)$$

Функцию потерь $h(\hat{y})$ в (3) принято называть «бинарной перекрестной энтропией» [5]. В формуле (3) величина $\hat{y}^{(t)} = \hat{f}(x^{(t)})$ – это полученная в процессе обучения оценка для $y^{(t)}$, а для оценивания точности обучения используется accuracy – доля правильно классифицированных вершин:

$$\alpha = \text{accuracy} = \frac{1}{n} \sum_{t=1}^n \mathbb{1}\{\hat{y}^{(t)} = y^{(t)}\} \in [0, 1].$$

Особенности использования ИНС для аппроксимации двоичных функций. При аппроксимации двоичных функций многих двоичных переменных на основе ИНС возникают две важные особенности, связанные:

- с наличием областей кусочного постоянства и многоэкстремальности целевой функции (3);
- выбором числа нейронов m .

Кусочное постоянство и многоэкстремальность функции потерь. Докажем лемму о свойствах коэффициентов ИНС (2).

Лемма 1. Если коэффициенты $\{a_{il}\}$ некоторого l -го нейрона $H_l^{(1)}$ ИНС (2) на множестве вершин X удовлетворяют условию

$$a_{0l} + \sum_{i=1}^s a_{il}x_i < 0, \forall x \in X, \quad (4)$$

то производная функции $h(\cdot)$, определяемой (3), по коэффициентам $\{a_{il}, b_l\}$ на множестве X равна 0.

Доказательство. Продифференцируем $h(\hat{y})$ по переменным $\{a_{il}, b_l\}$, используя уравнения (2) и (3):

$$\begin{aligned} \frac{\partial h(\hat{y})}{\partial a_{kl}} &= -\frac{1}{n} \sum_{t=1}^n (y^{(t)}(1 - \hat{y}^{(t)}) - (1 - y^{(t)})\hat{y}^{(t)}) b_l \mathbb{1} \left\{ a_{0l} + \sum_{i=1}^s a_{il}x_i^{(t)} > 0 \right\} \cdot \begin{cases} x_k^{(t)}, k \neq 0, \\ 1, k = 0, \end{cases} \\ \frac{\partial h(\hat{y})}{\partial b_l} &= -\frac{1}{n} \sum_{t=1}^n (y^{(t)}(1 - \hat{y}^{(t)}) - (1 - y^{(t)})\hat{y}^{(t)}) \cdot \begin{cases} \text{ReLU} \left(a_{0l} + \sum_{i=1}^s a_{il}x_i^{(t)} \right), l \neq 0, \\ 1, l = 0. \end{cases} \end{aligned}$$

Учитывая условие (4), $l > 0$ и вид функции $\text{ReLU}(\cdot)$, получаем, что производные обращаются в ноль.

Лемма доказана.

Из леммы 1 следует, что на множестве параметров ИНС

$$A_l = \left\{ (a_{0l}, a_{1l}, \dots, a_{sl}) : a_{0l} + \sum_{i=1}^s a_{il}x_i < 0, \forall x \in X \right\} \subset R^{s+1}$$

целевая функция кусочно постоянна по параметрам l -го нейрона. На таких множествах кусочного постоянства применение градиентного спуска для решения задачи минимизации (3) приводит к ухудшению сходимости. Еще одна трудность в решении задачи (3) состоит в многоэкстремальности целевой функции в (3).

Для преодоления трудностей, связанных с наличием областей $\{A_l\}$ кусочного постоянства, предлагается специально подбирать начальные значения параметров $\{a_{il}, b_l\}$ следующим образом. Вначале генерируем их как случайные величины согласно работам [6, 7] из распределений вероятностей:

$$a_{il} \sim N \left(0, \frac{2}{s} \right), b_l \sim U \left[-\frac{\sqrt{6}}{\sqrt{m+1}}, \frac{\sqrt{6}}{\sqrt{m+1}} \right],$$

где $N(\mu, \sigma^2)$ – нормальное распределение с математическим ожиданием μ и дисперсией σ^2 ; $U[a, b]$ – равномерное распределение, заданное на промежутке $[a, b]$. Если $(a_{0l}, a_{1l}, \dots, a_{sl}) \in A_l$, то для параметров $\{a_{0l}, \dots, a_{sl}\}$ l -го нейрона ($l \in \{1, \dots, m\}$) повторяем генерацию начальных значений до тех пор, пока не получим начальные значения вне области кусочного постоянства A_l .

О выборе числа нейронов. Будем использовать указанную выше геометрическую интерпретацию аппроксимации ИНС, связанную с раскраской вершин гиперкуба V^s . Каждый нейрон $H_l^{(1)}(x) = \text{ReLU}(a_{l0} + \sum_{i=1}^s a_{il}x_i)$ ($l \in \{1, \dots, m\}$), изображенный на рис. 1, порождает некоторую гиперплоскость, разделяющую множество вершин гиперкуба V^s на два подмножества $\Omega_{0l} = \{x \in V^s; H_l^{(1)}(x) = 0\}$ и $\Omega_{1l} = \{x \in V^s; H_l^{(1)}(x) > 0\}$. Исходя из такого способа разделения вершин, можно построить ИНС следующим образом: каждую вершину $x^{(l)} \in V^s$ с цветом 1 ($f(x^{(l)}) = 1$) отделить гиперплоскостью от остальных так, чтобы на этой вершине значение l -го нейрона $H_l^{(1)}(x^{(l)})$ стало положительным числом, а на остальных равнялось 0; $\{b_l\}$ задать из условий

$$\sigma(b_0) = \varepsilon, \sigma(b_l H_l^{(1)}(x^{(l)})) = 1 - \varepsilon \quad (l \in \{1, \dots, m\}),$$

где $\varepsilon < 1/2$ – достаточно малое положительное число.

Таким образом, верхняя граница числа нейронов существует, конечна и зависит от размерности гиперкуба:

$$1 \leq m \leq 2^s.$$

При этом число всевозможных различных раскрасок гиперкуба ограничено и равняется $|\mathcal{F}| = K = 2^{2^s}$. Обозначим $W(s, m)$ число различных раскрасок вершин гиперкуба V^s , для аппроксимации которых необходимо и достаточно m нейронов на скрытом слое ИНС (2). Отсюда следует

$$\sum_{m=1}^{2^s} W(s, m) = 2^{2^s}.$$

Построим оценку снизу для $W(s, 1)$, т. е. для количества раскрасок вершин s -мерного гиперкуба, полученных разделением этого множества вершин одной гиперплоскостью ($m = 1$).

Оценка снизу для $W(s, 1)$. Для построения оценки снизу докажем несколько лемм.

Лемма 2. Любой s -мерный гиперкуб V^s содержит в себе $2^{s-l} C_s^l$ граней размерности l .

Доказательство. Рассмотрим гиперкуб V^s размерности s . Грань размерности l представляет собой подмножество вершин гиперкуба, $s - l$ координат которых фиксированы. Число различных способов выбрать $s - l$ фиксированных координат из s возможных $C_s^{s-l} = C_s^l$. При этом каждой фиксированной координате нужно задать одно из двух значений 0 или 1. Количество различных наборов значений фиксированных координат равно 2^{s-l} .

Лемма доказана.

Лемма 3. Пусть A, B – два конечных множества, k – некоторое неотрицательное целое число, $C_k(*)$ – число различных способов выбрать k элементов из множества $*$. Тогда справедливо неравенство $C_k(A \cup B) \geq C_k(A) + C_k(B) - C_k(A \cap B)$.

Доказательство. Пусть $|A| = m_1$, $|B| = m_2$, $|A \cap B| = m_3$. Тогда число способов выбрать k элементов из множеств $A, B, A \cup B, A \cap B$ определяется формулами

$$\begin{aligned} C_k(A) &= \sum_{0 \leq k_1 \leq k} C_{m_1-m_3}^{k_1} C_{m_3}^{k-k_1}, C_k(B) = \sum_{0 \leq k_2 \leq k} C_{m_2-m_3}^{k_2} C_{m_3}^{k-k_2}, \\ C_k(A \cup B) &= \sum_{0 \leq k_1+k_2 \leq k} C_{m_1-m_3}^{k_1} C_{m_2-m_3}^{k_2} C_{m_3}^{k-k_1-k_2}, C_k(A \cap B) = C_{m_3}^k. \end{aligned}$$

Из этих формул следует, что числа $C_k(A)$, $C_k(B)$ и $C_k(A \cap B)$ входят в состав $C_k(A \cup B)$ (если подставить в сумме $k_2 = 0$, $k_1 = 0$, $k_1 = k_2 = 0$), откуда получается требуемое неравенство. Равенство достигается при $k = 0$ и $k = 1$.

Лемма доказана.

Условимся говорить, что k вершин ($1 \leq k \leq 2^s - 1$) линейно выделимы в гиперкубе V^s , если существует такая $(s - 1)$ -мерная гиперплоскость, которая разбивает V^s на два непересекающихся подмножества k и $2^s - k$ вершин.

Лемма 4. *Если на некоторой грани гиперкуба k вершин линейно выделимы, то эти же k вершин можно линейно выделить во всем гиперкубе.*

Доказательство. Для доказательства леммы достаточно показать возможность перехода к $(t + 1)$ -мерному гиперкубу от любой его t -мерной грани. Без ограничения общности будем считать, что t -мерная грань получена из гиперкуба путем фиксирования переменной x_{t+1} . В зависимости от значения x_{t+1} таких граней можно получить две: $V_0 = \{(x_1, \dots, x_t, 0) : x_i \in V\}$, $V_1 = \{(x_1, \dots, x_t, 1) : x_i \in V\}$, $V_0 \cup V_1 = V^{t+1}$, $V_0 \cap V_1 = \emptyset$. Обозначим T множество вершин гиперкуба, определяющих t -мерную грань ($T = V_0$ либо $T = V_1$). По условию леммы k вершин грани T линейно выделимы, т. е. существует гиперплоскость, задающаяся уравнением

$$L_t(x_1, \dots, x_t) = a_0 + \sum_{i=1}^t a_i x_i = 0, \quad (5)$$

которая разделяет грань T на два непересекающихся подмножества $T_+ = \{x \in T : L_t(x_1, \dots, x_t) > 0\}$ и $T_- = \{x \in T : L_t(x_1, \dots, x_t) < 0\}$: $T = T_+ \cup T_-$, $T_+ \cap T_- = \emptyset$, $|T_+| = k$, $|T_-| = 2^t - k$. Достроим гиперплоскость (5) так, чтобы на оставшихся вершинах $V^{t+1} \setminus T$ гиперкуба V^{t+1} левая часть нового уравнения давала отрицательное значение. Уравнение t -мерной гиперплоскости при этом будет иметь вид

$$L_{t+1}(x_1, \dots, x_t, x_{t+1}) = b_0 + b_1 x_{t+1} + L_t(x_1, \dots, x_t) = 0. \quad (6)$$

Коэффициенты b_0 , b_1 уравнения гиперплоскости (6) зададим из условий

$$\begin{cases} L_{t+1}(x_1, \dots, x_t, x_{t+1})|_{x \in T} = L_t(x_1, \dots, x_t), \\ L_{t+1}(x_1, \dots, x_t, x_{t+1})|_{x \in V^{t+1} \setminus T} < 0. \end{cases}$$

В зависимости от расположения грани T в гиперкубе V^{t+1} коэффициенты b_0 , b_1 уравнения гиперплоскости (6) будут принимать следующие значения:

- если $T = V_0$, то $b_0 = 0$, $b_1 = -A$, $A > \max_{x \in T} L_t(x_1, \dots, x_t)$;
- если $T = V_1$, то $b_0 = -A$, $b_1 = A$, $A > \max_{x \in T} L_t(x_1, \dots, x_t)$.

Построенная гиперплоскость разделяет гиперкуб V^{t+1} на два непересекающихся подмножества T_+ и $V^{t+1} \setminus T_+$.

Лемма доказана.

Исходя из лемм 2–4, построим дискретную функцию $Q(s, k)$ ($s, k \in \{0, 1, 2, \dots\}$), заданную следующим рекуррентным соотношением:

$$\begin{cases} Q(s, k) = \sum_{i=1}^s (-1)^{i+1} 2^i C_s^{s-i} Q(s - i, k), & \text{если } k \leq 2^{s-1}, \\ Q(s, k) = 0, & \text{если } k > 2^s, \\ Q(s, k) = Q(s, 2^s - k), & \text{если } k > 2^{s-1}, \\ Q(s, 0) = Q(s, 2^s) = 1. \end{cases} \quad (7)$$

Теорема. Значение функции $Q(s, k)$, полученное из рекуррентного соотношения (7), является оценкой снизу числа способов линейно выделять k вершин в s -мерном гиперкубе.

Доказательство. Доказательство следует из лемм 2–4. О том, что значение функции $Q(s, k)$ является оценкой снизу, говорит лемма 3. Второе и четвертое условия рекуррентного соотношения (7) задают граничные условия. Третье условие следует из того, что гиперплоскость делит множество вершин гиперкуба V^s на два подмножества с k и $2^s - k$ вершинами.

Теорема доказана.

Следствие. Чтобы найти оценку снизу для $W(s, 1)$, необходимо просуммировать по k значения функции $Q(s, k)$:

$$W(s, 1) \geq \sum_{k=0}^{2^s} Q(s, k).$$

В табл. 1 для примера представлены все значения функции $\{Q(s, k)\}$ для $s \leq 3$, $k \leq 8$. Жирным шрифтом выделены значения, задаваемые условиями 2 и 4 соотношения (7). Таблица значений функции $Q(s, k)$ заполняется построчно слева направо, снизу вверх.

Таблица 1

Пример заполнения таблицы значений функции $Q(s, k)$

Table 1

Example of filling in the table of the function values $Q(s, k)$

3	1	8	12	24	6	24	12	8	1	
2	1	4	4	4	1	0	0	0	0	
1	1	2	1	0	0	0	0	0	0	
0	1	1	0							
<i>s</i>		0	1	2	3	4	5	6	7	8
<i>k</i>										

Оценим затраты времени на заполнение таблицы. Условия 2 и 4 дают сложность $O(s2^s)$. Время, требуемое на заполнение строки под номером s , обозначим через $T(s)$. Этую строку можно разбить по k на промежутки $\{[1, 1], [2, 3], [4, 7], [8, 15], \dots, [2^{i-1}, 2^i - 1], \dots, [2^{s-1}, 2^s - 1]\}$, где каждое значение $Q(s, k)$ в i -м промежутке ($i = 0 \dots, s - 1$) требует $s - i$ значений из таблицы. Следовательно,

$$T(s) = \sum_{i=0}^{s-1} (s - i)2^i = 2^{s+1} - s - 2,$$

$$\sum_{t=1}^s T(t) = \sum_{t=1}^s (2^{t+1} - t - 2) = 2^{s+2} - \frac{s(s+1)}{2} - 2s - 4 = O(2^s).$$

Таким образом, общая сложность заполнения таблицы значений функции $Q(s, k)$ имеет порядок $O(s2^s)$. В табл. 2 представлено сравнение оценки $Q(s, k)$ с точным значением количества различных раскрасок для соответствующего значения k при $s \leq 3$.

Символом «» в табл. 2 обозначены случаи $k > 2^s$. В последней строке представлена вероятность события, состоящего в том, что случайно выбранная раскраска вершин гиперкуба требует для аппроксимации один нейрон на скрытом слое (оценка и точное значение).

Как видно из табл. 2, расхождение оценки и точного значения произошло при $k = 4$, $s = 3$. Это объясняется тем, что оценка $Q(s, k)$ учитывает только варианты, когда раскраска вершин гиперкуба сводится к раскраске вершин его грани (т. е. гиперкуба меньшей размерности). При этом не учитываются случаи, когда раскрашенные вершины принадлежат сразу нескольким таким граням. Например, вершины трехмерного куба ($s = 3$) можно разделить плоскостью $x_1 + x_2 + x_3 - \frac{3}{2} = 0$ (рис. 2).

Таблица 2

Сравнение оценки $Q(s, k)$ и точного значения для $s \leq 3$

Table 2

Comparison of the estimate $Q(s, k)$ and exact value for $s \leq 3$

Число вершин k цвета 1 <i>Number of vertices k of color 1</i>	Отрезок $s = 1$ <i>Section $s = 1$</i>		Квадрат $s = 2$ <i>Square $s = 2$</i>		Куб $s = 3$ <i>Cube $s = 3$</i>	
	Оценка $Q(s, k)$	Точное значение <i>Exact meaning</i>	Оценка $Q(s, k)$	Точное значение <i>Exact meaning</i>	Оценка $Q(s, k)$	Точное значение <i>Exact meaning</i>
0	1	1	1	1	1	1
1	2	2	4	4	8	8
2	1	1	4	4	12	12
3	-	-	4	4	24	24
4	-	-	1	1	6	14
5	-	-	-	-	24	24
6	-	-	-	-	12	12
7	-	-	-	-	8	8
8	-	-	-	-	1	1
Сумма	4	4	14	14	96	104
Вероятность	1	1	0,875	0,875	0,375	0,40625

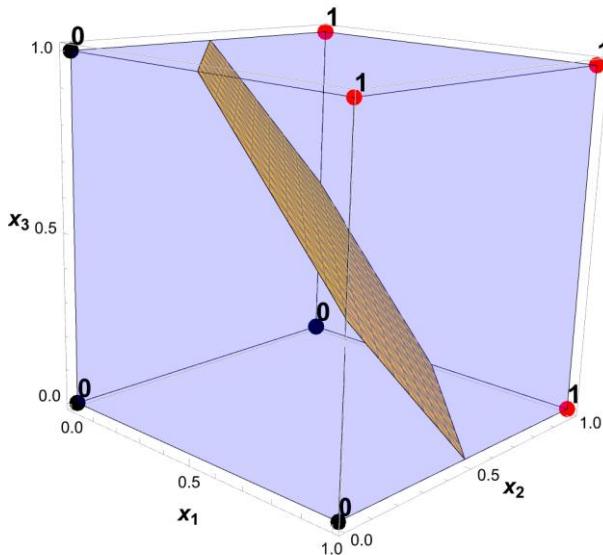


Рис. 2. Разделение вершин куба плоскостью $x_1 + x_2 + x_3 - \frac{3}{2} = 0$

Fig. 2. Separation of the cube vertices by the plane $x_1 + x_2 + x_3 - \frac{3}{2} = 0$

Такое разделение дает новую раскраску, которая не учитывается соотношением (7). Поворотами куба можно получить еще семь подобных раскрасок, что и объясняет различие между оценкой и точным значением в табл. 2 при $k = 4, s = 3$.

Применение ИНС для аппроксимации двоичных функций в задачах защиты информации
Аппроксимация порождающей функции генераторов псевдослучайных последовательностей. Рассмотрим задачу аппроксимации порождающих функций генераторов псевдослучайных последовательностей, основанных на регистрах сдвига с линейной обратной связью (РСЛОС) и регистрах сдвига с нелинейной обратной связью (РЧНОС), задаваемых следующим рекуррентным соотношением общего вида:

$$x_{\tau} = f(x_{\tau-1}, x_{\tau-2}, \dots, x_{\tau-s}), \tau = s+1, s+2, \dots$$

Для применения ИНС (2) обучающая выборка формировалась следующим образом:

$$x^{(t)} := (x_{t-1}, \dots, x_{t-s}), y^{(t)} := x_t, t \geq s+1.$$

Исследовались два РСЛОС [8] и шесть РЧНОС [9]. Для каждого из них найдено наименьшее число нейронов m_{min} , необходимых для безошибочной аппроксимации ($\alpha = 1$). Результаты представлены в табл. 3.

Таблица 3

Аппроксимация порождающих функций РСЛОС и РЧНОС

Table 3

Approximation of generating functions of LFSR and NLFSR

Число переменных s Number of variables s	Вид функции f Function type f	Число нейронов m_{min} Number of neurons m_{min}
7	$f = x_1 \oplus x_5$	2
15	$f = x_1 \oplus x_9$	2
17	$f = x_1 \oplus x_2 \oplus x_8 x_{11} \oplus x_{10} x_{16}$	6
17	$f = x_1 \oplus x_7 \oplus x_3 x_{10} \oplus x_8 x_{13}$	6
17	$f = x_1 \oplus x_2 \oplus x_4 \oplus x_{10} \oplus x_{13} \oplus x_8 x_{14}$	7
17	$f = x_1 \oplus x_2 \oplus x_8 \oplus x_{12} \oplus x_{14} \oplus x_7 x_{15}$	7
17	$f = x_1 \oplus x_4 \oplus x_9 \oplus x_{12} \oplus x_{13} \oplus x_4 x_{12}$	7
24	$f = x_1 \oplus x_2 \oplus x_9 \oplus x_{10} \oplus x_{16} \oplus x_8 x_{19}$	7

В ходе обучения ИНС при решении задачи аппроксимации РСЛОС и РЧНОС было замечено, что веса, исходящие на рис. 1 из фиктивных входных переменных (т. е. переменных, не влияющих на значение функции f), стремились к нулевому значению. Это показывает, что двухслойная ИНС (2) способна находить фиктивные переменные и исключать их влияние на результат аппроксимации.

Аппроксимация блоков подстановки. Рассмотрим задачу аппроксимации блока подстановки известного стандартного алгоритма шифрования ГОСТ 28147-89 [10] с точностью $\alpha = 1$. Этот блок подстановки представлен в шестнадцатеричной записи в табл. 4.

Таблица 4

Блок подстановки ГОСТ 28147-89

Table 4

Substitution block GOST 28147-89

x	0	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F
K_1	4	2	F	5	9	1	0	8	E	3	B	C	D	7	A	6
K_2	C	9	F	E	8	1	3	A	2	7	4	D	6	0	B	5
K_3	D	8	E	C	7	3	9	A	1	5	2	4	6	F	0	B
K_4	E	9	B	2	5	F	7	1	0	D	C	6	A	4	3	8
K_5	3	E	5	9	6	8	0	D	A	B	7	C	2	1	F	4
K_6	8	F	6	B	1	9	C	5	D	3	7	A	0	E	2	4
K_7	9	B	C	0	3	6	7	5	4	8	E	F	1	A	2	D
K_8	C	6	5	2	B	0	9	D	3	E	7	A	F	4	1	8

Блок подстановки представляет собой восемь функций K_1, \dots, K_8 , действующих из V^4 в V^4 . Каждую из этих векторных функций K_i можно разделить на четыре координатные функции, определяющие соответствующий бит значений функции K_i :

$$K_i(x) = y = (y_1, y_2, y_3, y_4) = (K_{i1}(x), K_{i2}(x), K_{i3}(x), K_{i4}(x)), x \in V^4, y \in V^4,$$

$$K_{il}(\cdot): V^4 \rightarrow V, i \in \{1, \dots, 8\}, l \in \{1, 2, 3, 4\}.$$

Для каждой координатной функции $K_{il}(\cdot)$ найдено наименьшее значение числа нейронов m_{min} , необходимых для ее аппроксимации. Результаты представлены в табл. 5.

Таблица 5
Минимальное число нейронов m_{min} для аппроксимации $K_{il}(\cdot)$
*Table 5
Minimum number of neurons m_{min} for approximation of $K_{il}(\cdot)$*

l	i							
	1	2	3	4	5	6	7	8
1	3	3	2	3	2	3	2	3
2	2	3	2	2	3	3	2	3
3	2	2	2	3	2	2	2	2
4	2	3	2	2	3	2	3	2

Заключение. В работе исследованы математические особенности применения ИНС для решения задач аппроксимации двоичных функций многих переменных, заключающиеся в наличии областей кусочного постоянства и многоэкстремальности целевой функции. Результаты статьи позволяют выбирать параметры двухслойной ИНС для повышения точности аппроксимации и иллюстрируются примерами аппроксимации порождающих функций генераторов псевдослучайных последовательностей.

Вклад авторов. *К. В. Латушкин* – аналитическое исследование, написание текста статьи, программная реализация модели, проведение численных экспериментов. *Ю. С. Харин* – построение модели, аналитическое исследование, подготовка текста статьи, анализ и интерпретация результатов исследования.

Список использованных источников

1. Gohr, A. Improving attacks on round-reduced speck32/64 using deep learning / A. Gohr // Advances in Cryptology – CRYPTO 2019: 39th Annual Intern. Cryptology Conf., Santa Barbara, CA, USA, 18–22 Aug. 2019. – Santa Barbara, 2019. – Pt. II. – P. 150–179.
2. Deep learning-based physical side-channel analysis / S. Picek, G. Perin, L. Mariot [et al.] // ACM Computing Surveys. – 2023. – Vol. 55(11). – P. 1–35.
3. Boanca, S. Exploring patterns and assessing the security of pseudorandom number generators with machine learning / S. Boanca // 16th Intern. Conf. on Agents and Artificial Intelligence, Rome, Italy, 24–26 Febr. 2024. – Rome, 2024. – Vol. 3. – P. 186–193.
4. Бетелин, В. Б. Математические задачи, связанные с искусственным интеллектом и искусственными нейронными сетями / В. Б. Бетелин, В. А. Галкин // Успехи кибернетики. – 2021. – Т. 2, № 4. – С. 6–14. – DOI: 10.51790/2712-9942-2021-2-4-1.
5. Николенко, С. Глубокое обучение. Погружение в мир нейронных сетей / С. Николенко, А. Кадурина, Е. Архангельская. – СПб. : Питер, 2018. – 480 с.
6. Glorot, X. Understanding the difficulty of training deep feedforward neural networks / X. Glorot, Y. Bengio // Proc. of the Thirteenth Intern. Conf. on Artificial Intelligence and Statistics, Sardinia, Italy, 13–15 May 2010. – Sardinia, 2010. – Vol. 9. – P. 249–256.
7. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification / K. He, X. Zhang, S. Ren, J. Sun // Proc. of the 2015 IEEE Intern. Conf. on Computer Vision, Santiago, Chile, 7–13 Dec. 2015. – Santiago, 2015. – P. 1026–1034.
8. Криптология / Ю. С. Харин, С. В. Агиевич, Д. В. Васильев, Г. В. Матвеев. – Минск : БГУ, 2023. – 511 с.
9. Dubrova, E. A list of maximum period NLFSRs / E. Dubrova // Cryptology ePrint Archive. – 2012. – URL: <https://eprint.iacr.org/2012/166> (date of access: 18.04.2025).
10. Программирование алгоритмов защиты информации / А. В. Домашев, М. М. Грунтович, В. О. Попов [и др.]. – М. : Нолидж, 2002. – 416 с.

References

1. Gohr A. Improving attacks on round-reduced speck32/64 using deep learning. *Advances in Cryptology – CRYPTO 2019: 39th Annual International Cryptology Conference, Santa Barbara, CA, USA, 18–22 August 2019*, pt. II, pp. 150–179.
2. Picek S., Perin G., Mariot L., Wu L., Batina L. Deep learning-based physical side-channel analysis. *ACM Computing Surveys*, 2023, vol. 55(11), pp. 1–35.
3. Boanca S. Exploring patterns and assessing the security of pseudorandom number generators with machine learning. *16th International Conference on Agents and Artificial Intelligence, Rome, Italy, 24–26 February 2024*, vol. 3, pp. 186–193.
4. Betelin V. B., Galkin V. A. *Mathematical problems of artificial intelligence and artificial neural networks*. Uspekhi kibernetiki [Russian Journal of Cybernetics], 2021, vol. 2, no. 4, pp. 6–14 (In Russ.). DOI: 10.51790/2712-9942-2021-2-4-1.
5. Nikolenko S., Kadurin A., Arkhangelskaya E. Glubokoe obuchenie. Pogruzhenie v mir nejronnyh setej. *Deep Learning. Dive into the World of Neural Networks*. Saint Petersburg, Piter, 2018, 480 p. (In Russ.).
6. Glorot X., Bengio Y. Understanding the difficulty of training deep feedforward neural networks. *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, Sardinia, Italy, 13–15 May 2010*, vol. 9, pp. 249–256.
7. He K., Zhang X., Ren S., Sun J. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification. *Proceedings of the 2015 IEEE International Conference on Computer Vision, Santiago, Chile, 7–13 December 2015*, pp. 1026–1034.
8. Kharin Yu. S., Agievich S. V., Vasilyev D. V., Matveev G. V. Kriptologiya. *Cryptology*. Minsk, Belorusskij gosudarstvennyj universitet, 2023, 511 p. (In Russ.).
9. Dubrova E. A list of maximum period NLFSRs. *Cryptology ePrint Archive*, 2012. Available at: <https://eprint.iacr.org/2012/166> (accessed 18.04.2025).
10. Domashev A. V., Gruntovich M. M., Popov V. O., Pravikov D. I., Shcherbakov A. Y., Prokofyev I. V. Programmirovaniye algoritmov zashchity informacii. *Programming of Information Security Algorithms*. Moscow, Nolidzh, 2002, 416 p. (In Russ.).

Информация об авторах

Латушкин Константин Вадимович, младший научный сотрудник, НИИ прикладных проблем математики и информатики Белорусского государственного университета.

E-mail: LatushkinKV@bsu.by

Харин Юрий Семенович, доктор физико-математических наук, академик НАН Беларуси, профессор, НИИ прикладных проблем математики и информатики Белорусского государственного университета.

E-mail: Kharin@bsu.by

Information about the authors

Konstantin V. Latushkin, Junior Researcher, Research Institute of Applied Problems of Mathematics and Informatics of the Belarusian State University.
E-mail: LatushkinKV@bsu.by

Yuriy S. Kharin, D. Sc. (Phys.-Math.), Acad. of the National Academy of Science of Belarus, Prof., Research Institute of Applied Problems of Mathematics and Informatics of the Belarusian State University.
E-mail: Kharin@bsu.by



УДК 004.056:004.89
DOI: 10.37661/1816-0301-2025-22-3-83-94

Оригинальная статья
Original Article

Программный модуль для детектирования мошеннических веб-сайтов с использованием классификации на основе методов машинного обучения

С. Н. Петров^{1✉}, А. О. Мяделец², Е. В. Кундас²

¹Белорусский государственный университет информатики и радиоэлектроники,
ул. П. Бровки, 6, Минск, 220013, Беларусь
✉E-mail: sergpetrov@inbox.ru

²Национальный детский технопарк,
ул. Франциска Скорины, 25/3, Минск, 220076, Беларусь

Аннотация

Цели. Целью исследования является разработка программного модуля для автоматического выявления фишинговых веб-сайтов с использованием алгоритмов машинного обучения для классификации сайтов.
Методы. Для достижения поставленной цели проведен анализ существующих датасетов, содержащих URL-адреса фишинговых сайтов, а также изучены датасеты для обработки естественного языка. Это позволило определить ключевые признаки, характерные для мошеннических ресурсов. Были созданы два набора данных (размерами 18,9 Мб и 1,08 Гб), включающих признаки URL и текстовое наполнение веб-страниц, с использованием разработанного парсера. Для классификации веб-ресурсов применялись алгоритмы машинного обучения, такие как SVM, Random Forest, Logistic Regression и Multilayer Perceptron (MLP). Также изучены возможности использования языковой модели TinyBERT для анализа текстового содержимого.

Результаты. По результатам проведенных исследований для работы с URL использована модель MLP (F1-score 99,3 %), а для анализа текстовой части веб-ресурса – модель TinyBERT (F1-score 95 %). Разработан программный модуль для выявления мошеннических веб-сайтов, состоящий из серверной части и браузерного расширения. Расширение собирает данные с веб-ресурса, передает их на сервер, где они анализируются обученными моделями машинного обучения. На сервере рассчитывается вероятность фишинговой активности, а результаты отображаются пользователю через интерфейс расширения. Реализация выполнена с использованием стека технологий Python 3.12, Flask, Pickle, Langdetect, Re и NLTK, а также JavaScript и Google Chrome API.

Заключение. Разработанный программный модуль был протестирован и продемонстрировал высокую эффективность в задачах классификации фишинговых сайтов. Теоретическая значимость работы заключается в применении современных алгоритмов машинного обучения для анализа текстового контента и URL. Практическая значимость заключается в создании готового решения для выявления фишинговых сайтов в реальном времени.

Ключевые слова: фишинговые сайты, мошенничество, машинное обучение, классификация, обработка естественного языка, датасеты

Для цитирования. Петров, С. Н. Программный модуль для детектирования мошеннических веб-сайтов с использованием классификации на основе методов машинного обучения / С. Н. Петров, А. О. Мяделец, Е. В. Кундас // Информатика. – 2025. – Т. 22, № 3. – С. 83–94. – DOI: 10.37661/1816-0301-2025-22-3-83-94.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 28.07.2025

Подписана в печать | Accepted 11.08.2025

Опубликована | Published 30.09.2025

Software module for detecting fraudulent websites using classification based on machine learning methods

Sergei N. Petrov^{1✉}, Artyom O. Myadelets², Elizaveta V. Kundas²

¹*Belarusian State University
of Informatics and Radioelectronics,
st. P. Brovki, 6, Minsk, 220013, Belarus*
✉E-mail: sergpetrov@inbox.ru

²*National Children's Technopark,
st. Francis Skorina, 25/3, Minsk, 220076, Belarus*

Abstract

Objectives. Phishing web resources are among the most common tools of online fraud aimed at obtaining users' confidential information. The goal of this research was to develop a software module for the automatic detection of phishing websites using machine learning methods.

Methods. To achieve this goal, an analysis of existing datasets containing phishing website URLs was conducted, along with the study of datasets for natural language processing (NLP). This enabled the identification of key features characteristic of fraudulent resources. Two datasets were created (sizes: 18.9 MB and 1.08 GB), incorporating URL attributes and web page content, using a custom-developed parser. Machine learning algorithms such as SVM, Random Forest, Logistic Regression, and Multilayer Perceptron (MLP) were applied for website classification. The potential of the TinyBERT language model for analyzing textual content was also explored.

Results. The analysis revealed that the MLP model demonstrated the best performance for URL classification, while the TinyBERT model excelled in analyzing textual content. A software module was developed, consisting of a server-side application and a browser extension. The extension collects data from web resources, transmits them to the server, where trained machine learning models analyze the information. The server calculates the likelihood of phishing activity, and the results are displayed to the user via the extension's interface. The implementation utilized a technology stack including Python 3.12, Flask, Pickle, Langdetect, Re, NLTK, JavaScript, and the Google Chrome API.

Conclusion. The developed software module was tested and demonstrated high efficiency in phishing website classification tasks. The theoretical significance of the work lies in applying modern machine learning algorithms for analyzing textual content and URLs. The practical significance is reflected in the creation of a ready-to-use solution for real-time phishing site detection.

Keywords: phishing websites, fraud, machine learning, classification, natural language processing, datasets

For citation. Petrov S. N., Myadelets A. O., Kundas E. V. *Software module for detecting fraudulent websites using classification based on machine learning methods*. Informatika [Informatics], 2025, vol. 22, no. 3, pp. 83–94 (In Russ.). DOI: 10.37661/1816-0301-2025-22-3-83-94.

Conflict of interest. The authors declare of no conflict of interest.

Введение. Мошенническим сайтом (веб-ресурсом) является любой сайт, созданный для обмана пользователей с целью получения незаконной прибыли. Частным случаем мошеннического сайта является фишинговый сайт, который имитирует настоящий сайт (реально существующий, законный сайт) с целью получения конфиденциальной информации пользователей, такой как пароли учетных записей, номера кредитных карт, паспортные и персональные данные. В Республике Беларусь существует уголовная ответственность за мошенничество с использованием веб-ресурсов в соответствии со статьей 212 УК РБ «Хищение имущества путем модификации компьютерной информации».

Фишинг (от англ. phishing, производное от fishing – «рыбная ловля», «выуживание») представляет собой вид мошенничества, основанный на использовании методов социальной инженерии. Злоумышленники выдают себя за представителей известных организаций, банков или сервисов и создают поддельные веб-страницы, которые практически не отличаются от оригинальных [1]. Попав на такую страницу, пользователь может даже не подозревать, что взаимодействует с поддельным сервисом, созданным мошенниками.

Мошеннический сайт (веб-ресурс) можно определить по нескольким характерным признакам. Один из самых очевидных и часто встречающихся признаков – это искаженный URL-адрес. Мошенники часто используют тайпсквоттинг, заменяя буквы похожими символами или изменяя структуру адреса. Например, вместо «bank.com» пользователь может увидеть адрес «bank.com», где латинская буква «а» заменена на кириллическую «а», что визуально незаметно. Также мошенники могут использовать другую доменную зону (например, .com вместо .ru), допускать намеренные опечатки или добавлять лишние символы в адресе. Все это делает поддельные сайты (домены) похожими на оригинальные и затрудняет их распознавание.

Кроме того, фишинговые сайты часто можно узнать по содержимому страниц. Мошенники стремятся вызвать у пользователя чувство срочности и заставить его действовать немедленно. Текст на таких страницах может содержать ошибки или быть сформулирован так, чтобы побудить пользователя раскрыть личные данные. Например, популярным приемом является обещание крупных выигрышей, бонусов или специальных предложений, которые доступны только ограниченное время. Такие уловки призваны отвлечь внимание от подозрительных элементов сайта и побудить пользователя действовать импульсивно.

Мошеннические веб-ресурсы создаются массово, что также является важным признаком фальшивого сайта. Часто можно заметить, что на таких страницах используются одни и те же шаблоны, а контактные данные, такие как электронные адреса или номера телефонов, могут повторяться на разных ресурсах. Все это свидетельствует о том, что за созданием подобных сайтов стоят организованные группы мошенников, которые используют автоматизированные инструменты для быстрого клонирования веб-страниц.

Количество мошеннических сайтов растет с каждым годом, и фишинговые атаки становятся все более сложными и масштабными. Это создает серьезные риски как для обычных пользователей, так и для крупных компаний, которым приходится тратить значительные ресурсы на обеспечение безопасности своих клиентов. В условиях таких угроз традиционные методы защиты становятся недостаточными, и все большую роль начинают играть технологии машинного обучения.

Применение алгоритмов машинного обучения, позволяющих обрабатывать большие объемы данных и выявлять скрытые закономерности, обеспечивает возможность классификации веб-сайтов на подлинные и мошеннические. Например, обученная модель может учитывать различные признаки URL-адреса, структуру HTML-кода и даже содержимое страницы, чтобы предсказать вероятность того, что данный ресурс является фишинговым. Процесс детектирования мошеннических сайтов сводится к решению задачи классификации, в которой все множество сайтов делится на два подмножества (класса) – мошеннические сайты и легитимные (нормальные).

Целью исследовательского проекта является разработка программного модуля с использованием машинного обучения для выявления мошеннических веб-ресурсов. Для достижения этой цели необходимо решить несколько задач: проанализировать существующие алгоритмы классификации, создать набор данных для обучения моделей, выбрать оптимальные модели классификации, реализовать программный модуль анализа веб-ресурсов на основе выбранных моделей.

Наборы данных для обучения моделей. Датасет в контексте машинного обучения – это набор данных, который используется для обучения модели или ее тестирования. Датасеты для выявления мошеннических веб-ресурсов могут быть собраны из различных источников, включая специализированные базы данных, общедоступные репозитории, или создаваться вручную на основе анализа реальных примеров мошеннических сайтов. Датасет состоит из набора объектов, каждый из которых содержит одну или несколько функций и соответствующие признаки – индивидуальные измеряемые свойства или характеристики. Примером таких признаков являются параметры, извлеченные из URL-адресов [2]. Это статистические данные, исходя из которых можно определить, является сайт безопасным для использования или нет. Признаки могут включать в себя протокол, доменное имя, путь к ресурсу, количество определенных символов в URL-адресе, наличие iframe и т. д.

Программному модулю необходимо анализировать как URL-адреса веб-ресурсов, так и текстовое содержимое (контент) страниц [3]. Это требует подготовки двух различных датасетов. Первый будет предназначен для обучения модели выявлению признаков мошенничества непосредственно в URL, таких как подозрительные символы, нестандартные доменные зоны или подменные домены. Второй датасет необходим для обучения NLP-модели. Обработка естественного языка (Natural Language Processing, NLP) позволяет анализировать текст на страницах сайтов, чтобы выявлять подозрительные паттерны, такие как завлекающие сообщения или запросы конфиденциальной информации.

Были рассмотрены открытые ресурсы по тематике машинного обучения, и проведен анализ популярных датасетов [4], результаты которого представлены в табл. 1.

Таблица 1

Информация о датасетах для выявления фишинговых URL

Table 1

Information about Datasets for Phishing URL Detection

Название <i>Title</i>	PhiUSIIL Phishing URL	Phishing Websites Dataset	Phishing Websites Dataset Cleaned	Webpage Phishing Detection Dataset
Ссылка <i>Link</i>	https://archive.ics.uci.edu/dataset/967/phiusiil+phishing+url+dataset/	https://data.mendeley.com/datasets/72ptz43s9v/1/	https://www.kaggle.com/datasets/prishasawhney/phishing-url-website-dataset-cleaned/	https://www.kaggle.com/datasets/shashwatwork/web-page-phishing-detection-dataset/
Год издания <i>Year of Publication</i>	2023	2020	2024	2020
Размер, Мб <i>Size (MB)</i>	54,2	23,9	21,77	3,66
Кол-во URL-адресов <i>Number of URLs</i>	235 795	88 647	176 263	11 430
Кол-во признаков <i>Number of Features</i>	54	111	20	87

На рис. 1 изображен график распределения классов датасетов, приведенных в табл. 1.

Датасет Webpage Phishing Detection Dataset обладает сбалансированным соотношением классов, что делает его привлекательным для обучения модели. Однако его существенным недостатком является небольшое количество URL-адресов по сравнению с другими наборами данных, что ограничивает его использование при работе с более сложными моделями.

Поиск датасетов для обучения NLP-модели не был результативным. В открытом доступе практически нет наборов данных на русском языке, которые бы подходили для анализа содержимого фишинговых сайтов. Большинство доступных датасетов основаны на английском языке или не содержат необходимой информации для успешного решения поставленной задачи.

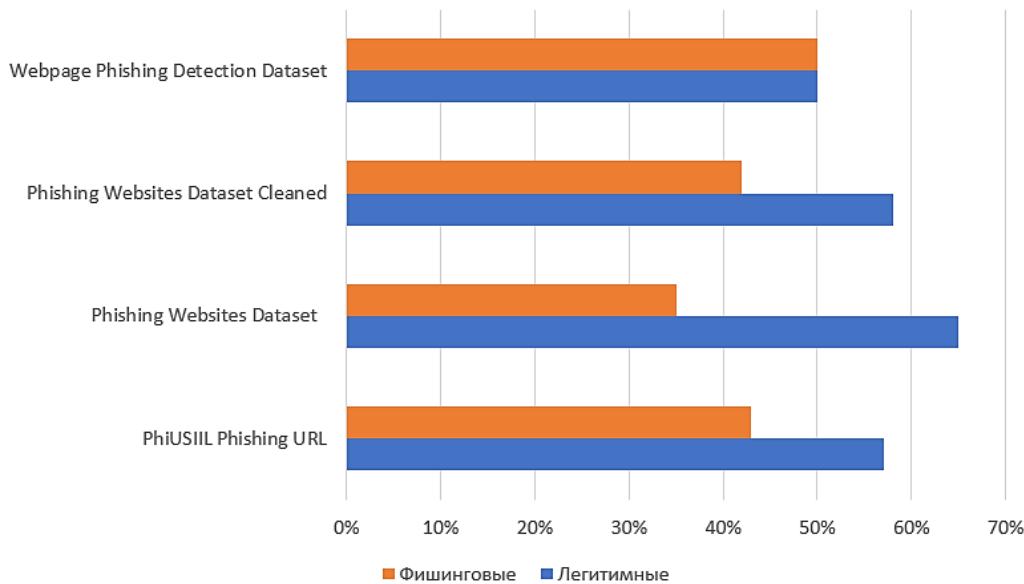


Рис. 1. Распределение классов в датасетах

Fig. 1. Classes Distribution in Datasets

Наиболее подходящим вариантом оказался Dataset Advert-Spam (Russia) (<https://www.kaggle.com/datasets/sanarovmichael/dataset-advert-spam>) на платформе Kaggle. Его объем составляет 2,6 Мб, и он включает только примеры фишинговых спам-сообщений. Основной контент датасета составляют тексты, побуждающие оформить кредит или банковский вклад, навязчивая реклама с заманчивыми предложениями, а также сообщения с орфографическими ошибками.

Анализ открытых источников показал отсутствие готовых решений для поставленной задачи. В связи с этим было принято решение создать собственные датасеты, которые позволят систематизировать данные, необходимые для обучения моделей на основе анализа как URL-адресов, так и текстов веб-страниц.

Создание собственных наборов данных. Для создания собственных датасетов был разработан программный компонент (парсер), который автоматически собирает и анализирует данные из URL-адресов и HTML-кода страниц. Код написан на языке программирования Python из-за его кроссплатформенности, простоты и наличия необходимых библиотек для обработки данных. В качестве среды разработки использовалась Visual Studio Code.

За основу создания датасета, содержащего признаки URL, был взят Webpage Phishing Detection Dataset. На его базе сформирован датасет, включающий данные из Webpage Phishing Detection Dataset и дополненный данными с платформ PhishTank (<https://dev.phishtank.com>) и OpenPhish (<https://openphish.com>). Эти платформы служат для обмена данными и информацией о фишинге и содержат большое количество ссылок на фишинговые ресурсы. Однако сами по себе данные на этих платформах не подходят для обучения моделей и должны быть обработаны для извлечения информативных признаков. Были извлечены признаки из URL. После этого парсером обрабатывались непосредственно веб-страницы, размещенные по указанным URL.

Алгоритм работы парсера для формирования URL-датасета:

1. Чтение URL-адресов из исходного файла.
2. Анализ структуры URL (длина, количество символов, поддоменов и т. д.).

3. Проверка на наличие подозрительных признаков (наличие слов типа login, secure).
 4. Скачивание веб-страницы (если доступно) для анализа HTML-кода.
 5. Сохранение результатов (все извлеченные характеристики записываются в CSV-файл).
- Получился датасет размером 18,9 Мб, содержащий около 88 687 URL-адресов, каждый из которых анализируется по 63 признакам. Примеры 25 признаков (выборочно) приведены в табл. 2.

Таблица 2

Информация о датасетах для выявления фишинговых URL

Table 2

Information about Datasets for Phishing URL Detection

Признак <i>Feature</i>	Описание признака <i>Description of the feature</i>
url	URL-адрес
length_url	Длина URL
length_hostname	Длина имени хоста
ip	Является ли имя хоста IP-адресом
nb_dots	Количество точек в URL
nb_hyphens.	Количество дефисов в URL
nb_at	Количество символов @ в URL
nb_qm	Количество символов ? в URL
nb_and	Количество символов & в URL
nb_or	Количество вхождений подстроки or в URL
http_in_path	Наличие подстроки http в пути
https_token	Наличие подстроки https в URL
ratio_digits_url	Отношение числа цифр к длине URL
ratio_digits_host	Отношение числа цифр к длине имени хоста
punycode	Наличие Punycode, т. е. подстроки xn--
port	Наличие порта в URL (например, :8080)
tld_in_path	Наличие доменного уровня в пути
tld_in_subdomain	Наличие доменного уровня в поддомене
nb_redirection	Количество перенаправлений
nb_external_redirection	Количество внешних перенаправлений
iframe	Наличие элемента iframe на странице
popup_window	Наличие всплывающих окон
right_clic	Блокировка правой кнопки мыши на странице
phish_hints	Наличие ключевых слов, часто встречающихся на фишинговых сайтах (например, login, secure, account)
domain_in_brand	Наличие известных брендов в домене

Алгоритм работы парсера для формирования текстового датасета:

1. Чтение URL-адресов из исходного файла.
 2. Анализ HTML-кода (удаляет HTML-теги, выполняет стемминг и удаляет стоп-слова).
 3. Векторизация текста с использованием TfidfVectorizer. TfidfVectorizer – это один из инструментов NLP, используемый для преобразования текстовых данных в числовой формат на основе статистической меры TF-IDF (Term Frequency-Inverse Document Frequency). Он оценивает важность слов в документе относительно всего корпуса, снижая влияние часто встречающихся, но малоинформативных слов.
 4. Сохранение результатов (все извлеченные характеристики записываются в joblib файл).
- Размер итогового текстового датасета составляет 1,08 Гб. В результате были созданы два датасета размерами 18,9 Мб и 1,08 Гб соответственно для выявления мошеннических веб-ресурсов путем анализа их URL и текстового наполнения.
- Распределение классов URL-датасета показано на рис. 2, *a*, а распределение классов для текстового датасета – на рис. 2, *b*.

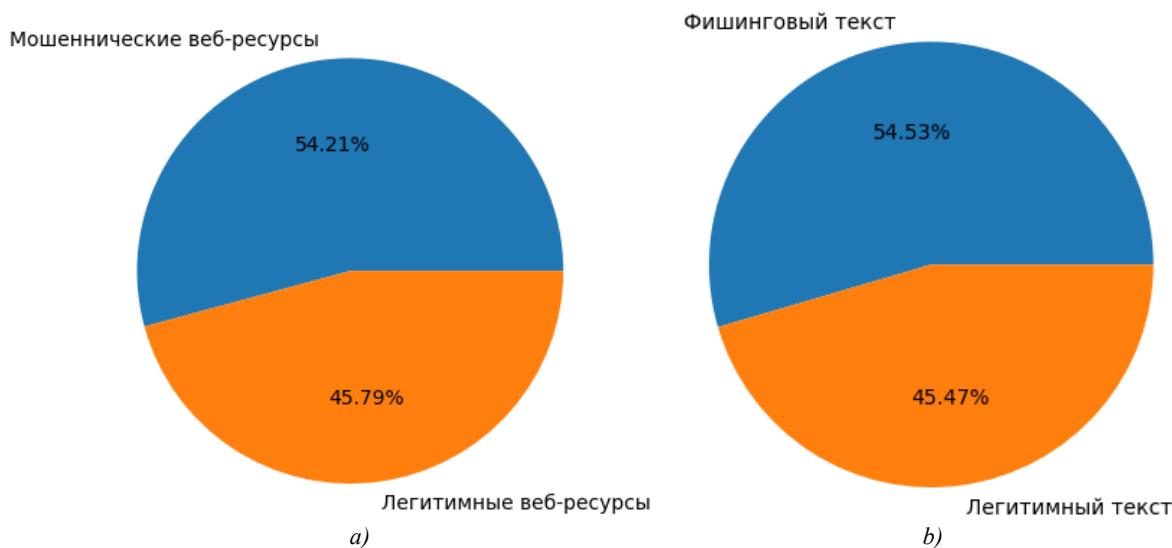


Рис. 2. Распределение классов в датасете: a) URL-датасет; b) текстовый датасет

Fig. 2. Class Distribution in the dataset: a) URL dataset; b) text dataset

Выбор оптимальной модели для классификации веб-ресурсов. Для выявления мошеннических веб-ресурсов были выбраны четыре алгоритма машинного обучения [5]: Support Vector Machine, Random Forest, Logistic Regression и Multilayer Perceptron.

Support Vector Machine (SVM) – надежный алгоритм для задач классификации, особенно с высокоразмерными данными. Линейное ядро подходит для линейно разделимых данных, RBF – для нелинейных, полиномиальное ядро применяется для сложных зависимостей, сигмоидное используется реже из-за нестабильности.

Random Forest (RF) объединяет несколько деревьев решений для повышения точности и устойчивости модели, особенно эффективен при большом количестве признаков.

Logistic Regression (LR) хорошо подходит для бинарной классификации и позволяет оценивать вероятность принадлежности к классам.

Multilayer Perceptron (MLP) – это нейросеть, решающая как линейные, так и нелинейные задачи за счет скрытых слоев и функций активации.

Для оценки моделей машинного обучения в задаче классификации используются различные метрики, каждая из которых отражает определенный аспект работы модели [6]:

- Accurasy отражает долю верных предсказаний, но на несбалансированных данных может вводить в заблуждение, так как модель может игнорировать редкий класс и все равно показывать высокий результат;

- Precision показывает, сколько из предсказанных мошенничеств действительно оказались мошенничеством;

- Recall измеряет, сколько из всех реальных случаев мошенничества модель смогла обнаружить;

- F1-score объединяет Precision и Recall в одно значение и позволяет сбалансированно оценить модель. Это необходимо, чтобы минимизировать ложные срабатывания и не пропускать реальные случаи мошенничества.

Для подбора гиперпараметров использовался метод GridSearchCV, который перебирает все возможные комбинации параметров и оценивает их с помощью кросс-валидации, что позволяет автоматически находить оптимальные настройки модели и избегать ручного подбора. Обучение моделей проводилось в Google Colab, который предоставляет бесплатный доступ к облачным вычислительным ресурсам, включая GPU, что ускорило процесс обучения.

В табл. 3 приведены лучшие результаты каждой модели (по точности и времени обучения и предсказания) по обработке URL.

Таблица 3

Результаты моделей при работе с URL

Table 3

Model Results for working with URL

Алгоритм <i>Algorithm</i>	Точность, % <i>Accuracy, %</i>	Полнота, % <i>Recall, %</i>	Достоверность, % <i>Precision, %</i>	F1-мера, % <i>F1-score, %</i>	Время обучения, с <i>Trainig time, s</i>	Время предсказания одной строки, с <i>Time for predicting a single line, s</i>
RF	99,3	99,4	99,6	99,5	5,7	0,21
LR	98,7	98,6	99,6	99,1	2	0,01
SVM	91	99,5	89,4	94,1	2113	0,08
MLP	99	98,9	99,7	99,3	40	0,02

Рассмотренные модели не показали высоких результатов при анализе текстового содержимого веб-страниц. Лучший результат показала модель Random Forest (точность 54,5 %, полнота 99,8 %, достоверность 54,5 %, F1-мера 70,6 %). По результатам поиска решения для анализа текстовой части веб-ресурса использована большая языковая модель (LLM) BERT [7, 8], а именно TinyBERT [9] – компактная версия модели, оптимизированная для ускорения работы и уменьшения вычислительных затрат. TinyBERT эффективна для задач обработки естественного языка, таких как классификация текстов и анализ тональности, а за счет меньшего числа слоев и параметров подходит для приложений, работающих в реальном времени. Модель была дообучена с использованием созданного текстового датасета, описанного ранее.

Дообучение модели проводилось с использованием технологии переноса знаний, что позволило сократить время обучения и повысить точность. TinyBERT научилась успешно распознавать признаки фишинговых текстов и сохранять высокую точность даже на коротких сообщениях или текстах с орфографическими ошибками. Полученные результаты представлены в табл. 4.

Таблица 4

Результаты работы модели TinyBERT

Table 4

Results of TinyBERT working

Модель <i>Model</i>	Точность, % <i>Accuracy, %</i>	Полнота, % <i>Recall, %</i>	Достоверность, % <i>Precision, %</i>	F1-мера, % <i>F1-score, %</i>	Время обучения, с <i>Trainig time, s</i>	Время предсказания одной строки, с <i>Time for predicting a single line, s</i>
TinyBERT	95	91	99	95	1113	0,044

Из табл. 4 видно, что LLM-модель показала очень высокую точность распознавания фишинговых текстов, а время предсказания оказалось меньше, чем у моделей SVM, Logistic Regression, Random Forest и Multilayer Perceptron. Единственным недостатком оказалось долгое время обучения модели – порядка 18 мин. Однако при работе модуля в реальных условиях это не будет являться существенным недостатком. Проводить дообучение модели можно будет с определенной периодичностью по мере необходимости.

Таким образом, при разработке программного модуля для анализа URL выбрана модель MLP, а для анализа текстовой части – модель TinyBERT.

Разработка программного модуля для классификации веб-сайтов. Программный модуль для выявления мошеннических веб-сайтов состоит из серверной части и браузерного расширения. Расширение собирает данные с веб-ресурса и отправляет их на сервер, где они анализируются обученными ML-моделями. Сервер принимает данные методом POST, обрабатывает их (стемминг, удаление стоп-слов), предсказывает вероятность того, что сайт является фишинговым, после чего по методу POST возвращает результат в расширение, которое отображает результаты для пользователя (рис. 3). В проекте использовался стек технологий, включающий Python 3.12

для серверной части и анализа данных с помощью библиотек Flask, Pickle, Langdetect, Re и NLTK. Браузерное расширение разработано на JavaScript с использованием Google Chrome API и оформлено с помощью HTML/CSS. Для написания и отладки кода использовалась среда Visual Studio Code. Результат работы программного модуля показан на рис. 4.

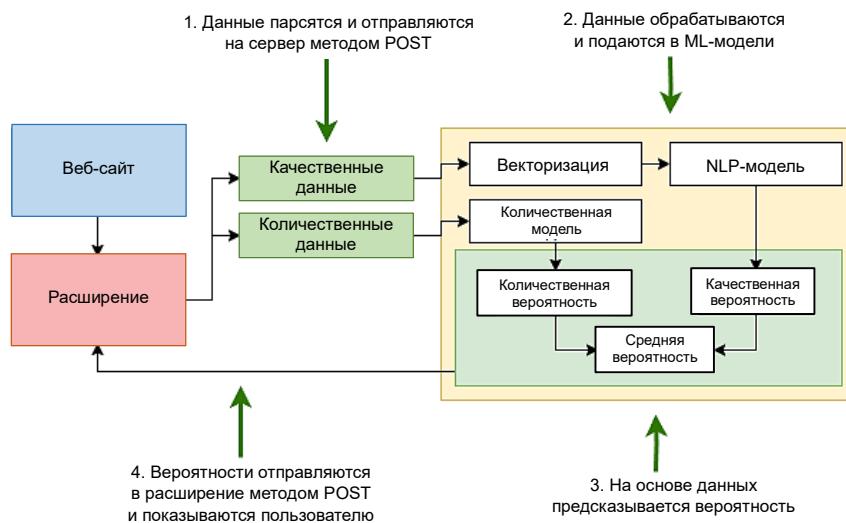


Рис. 3. Схема работы программного модуля

Fig. 3. Operating diagram of the software module

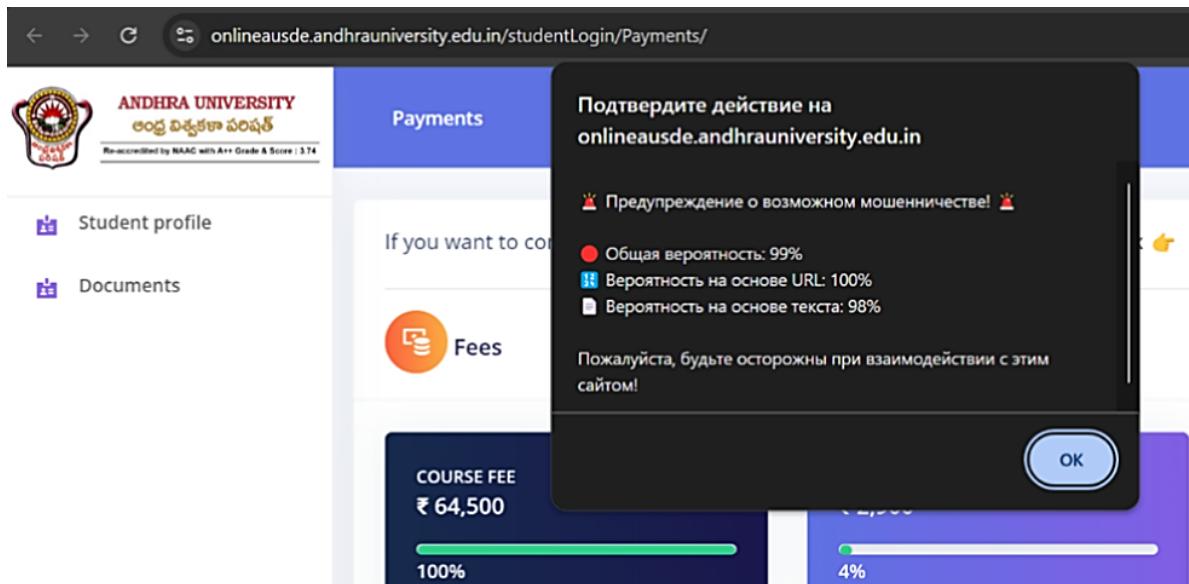


Рис. 4. Пример уведомления о мошенничестве

Fig. 4. Fraud notification example

Модуль был протестирован на группе веб-сайтов, заранее разделенных на заведомо мошеннические (рис. 5, а) и легитимные (рис. 5, б). В результате тестирования модуль показал высокую степень эффективности выявления такого типа ресурсов. Среднее время предсказания составило 0,11 с.

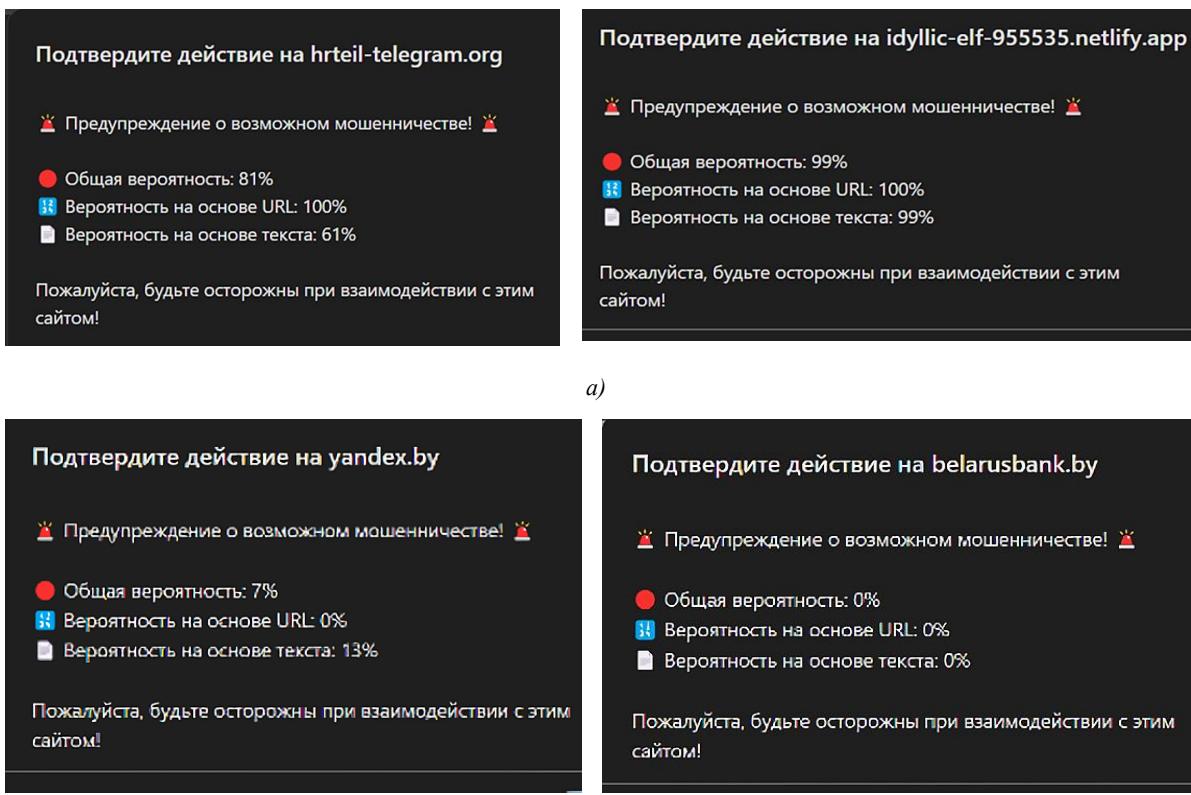


Рис. 5. Результаты тестирования: а) на заведомо мошеннических веб-сайтах;
б) на легитимных веб-сайтах

Fig. 5. Test results: a) on obviously fraudulent websites; b) on obviously legitimate websites

Результаты проверки ряда веб-ресурсов представлены в табл. 5.

Таблица 5

Результаты проверки веб-ресурсов разработанным модулем

Table 5

Results of checking web resources by the developed module

URL	Вероятность по URL, % <i>Probability by URL, %</i>	Вероятность по тексту, % <i>Probability by text, %</i>	Средняя вероятность, % <i>Average probability, %</i>
https://www.bsuir.by	0	0	0
https://mail.ru	0	0	0
https://habr.com/	0	0	0
https://yandex.by	0	13	7
https://bsu.by	0	32	16
https://domain.by	0	34	17
http://myfin.by	0	32	16
https://aliexpress.by	2	59	30
https://belta.by	0	29	15
https://president.gov.by	0	0	0
https://connect-chain-wallet.web.app/app	100	53	77
https://accoun-at-risk.github.io/anesh-here	100	99	100
https://steamcommunity.ru	100	99	100
https://busca-lphone.com	98	100	100
https://metmaskloginie.webflow.io/	100	99	99
https://www.metamask-io-help.walletallinone.com/	100	45	73
http://facebook.focal.us.kg/	99	99	95
https://v5-uniswap.info/	100	91	95

Заключение. Проведен анализ открытых датасетов для обучения моделей анализу URL и текстового наполнения веб-ресурсов, результаты которого показали отсутствие подходящих решений для данного проекта. С применением разработанного для этих целей парсера были созданы два датасета размерами 18,9 Мб и 1,08 Гб для выявления мошеннических веб-ресурсов путем анализа их URL и текстового наполнения. По результатам проведенных исследований для работы с URL использована модель MLP (F1-score 99,3 %), а для анализа текстовой части веб-ресурса – модель TinyBERT (F1-score 95 %).

Разработан программный модуль для выявления мошеннических веб-сайтов, состоящий из серверной части и браузерного расширения. Результаты проверки ряда веб-ресурсов показали высокую эффективность разработанного модуля. В рамках работы сервер запускался локально. В перспективе – реализация серверной части онлайн, что позволит большому числу пользователей осуществлять проверку веб-ресурсов, используя одно только легковесное браузерное расширение, а поддержку серверной части будут осуществлять разработчики.

С исходным кодом программного модуля, а также файлами исследования ML-моделей можно ознакомиться в репозитории Github по ссылке <https://github.com/Param0rph/PhishDetect>. Для того чтобы установить браузерное расширение, необходимо перейти в chrome://extensions/ в браузере Google Chrome, включить режим разработчика (Developer mode), в панели управления расширениями выбрать Load unpacked и загрузить папку с расширением.

Дополнительные материалы к проекту расположены по ссылке https://drive.google.com/drive/folders/10oIYFJDF_gtpgru4l1cgjZSIeVVJbUZq?usp=sharing.

Вклад авторов. С. Н. Петров определил цели исследования и задачи, которые необходимо было решить для их достижения, принял участие в интерпретации и обобщении полученных результатов, написал текст рукописи. А. О. Мяделец провел экспериментальные исследования эффективности моделей классификации, спроектировал и разработал программный модуль. Е. В. Кундас выполнила сравнительный анализ существующих подходов к обнаружению мошеннических веб-ресурсов, провела анализ открытых датасетов для выявления мошеннических веб-ресурсов, сформировала датасеты для обучения моделей с использованием разработанного парсера.

Список использованных источников

1. Завьялов, А. Н. Интернет-мошенничество (фишинг): проблемы противодействия и предупреждения / А. Н. Завьялов // Baikal Research Journal. – 2022. – Т. 13, № 2. – С. 36.
2. Machine learning techniques for detecting phishing URL attacks / D. T. Mosa, M. Y. Shams, A. A. Abohany [et al.] // Computers, Materials & Continua. – 2023. – Vol. 75, no. 1. – P. 1271–1290. – DOI: 10.32604/cmc.2023.036422.
3. A phishing-attack-detection model using natural language processing and deep learning / E. Benavides-Astudillo, W. Fuertes, S. Sanchez-Gordon [et al.] // Applied Sciences. – 2023. – Vol. 13, iss. 9. – P. 5275.
4. Петров, С. Н. Датасеты для обучения моделей обнаружению мошеннических веб-ресурсов / С. Н. Петров, А. О. Мяделец, Е. В. Кундас // Лучшие студенческие исследования 2025 : сб. ст. IV Междунар. науч.-исслед. конкурса. – Пенза : МЦНС «Наука и Просвещение». – 2025. – С. 27–32.
5. Жерон, О. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем / О. Жерон ; пер. с англ. – СПб. : ООО «Альфа-книга», 2018. – 688 с.
6. Шакла, Н. Машинное обучение и TensorFlow / Н. Шакла ; пер. с англ. – СПб. : Питер, 2019. – 336 с.
7. Koroteev, M. V. BERT: A Review of Applications in Natural Language Processing and Understanding / M. V. Koroteev. – URL: <https://arxiv.org/pdf/2103.11943.pdf> (date of access: 17.03.2025).
8. Worth, P. J. Word embeddings and semantic spaces in natural language processing / P. J. Worth // International Journal of Intelligence Science. – 2023. – Vol. 13, no. 1. – P. 1–21. – DOI: 10.4236/ijis.2023.131001.
9. TinyBERT: Distilling BERT for Natural Language Understanding / X. Jiao, Y. Yin, L. Shang [et al.]. – URL: <https://arxiv.org/pdf/1909.10351v5.pdf> (date of access: 17.03.2025). – DOI: 10.48550/arXiv.1909.10351.

References

1. Zavyalov A. N. Internet fraud (phishing): problems of counteraction and prevention. *Baikal Research Journal*, 2022, vol. 13, no. 2, p. 36 (In Russ.).
2. Mosa D. T., Shams M. Y., Abohany A. A., El-kenawy E.-S. M., Thabet M. Machine learning techniques for detecting phishing URL attacks. *Computers, Materials & Continua*, 2023, vol. 75, no. 1, pp. 1271–1290. DOI: 10.32604/cmc.2023.036422.
3. Benavides-Astudillo E., Fuertes W., Sanchez-Gordon S., Nuñez-Agurto D., Rodríguez-Galán G. A phishing-attack-detection model using natural language processing and deep learning. *Applied Sciences*, 2023, vol. 13, iss. 9, p. 5275.
4. Petrov S. N., Myadelets A. O., Kundas E. V. *Datasets for training models to detect fraudulent web resources*. Luchshie studencheskie issledovanija 2025 : sbornik statej IV Mezhdunarodnogo nauchno-issledovatel'skogo konkursa [Best Student Research 2025: Collection of Articles of the IV International Research Competition]. Penza, Nauka i Prosveshchenie, 2025, pp. 27–32 (In Russ.).
5. Géron A. *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, 2017, 572 p.
6. Shukla N. *Machine Learning with TensorFlow*. Manning, 2018, 272 p.
7. Koroteev M. V. *BERT: A Review of Applications in Natural Language Processing and Understanding*. Available at: <https://arxiv.org/pdf/2103.11943> (accessed 17.03.2025).
8. Worth P. J. Word embeddings and semantic spaces in natural language processing. *International Journal of Intelligence Science*, 2023, vol. 13, no. 1, pp. 1–21. DOI: 10.4236/ijis.2023.131001.
9. Jiao X., Yin Y., Shang L., Jiang X., Chen X., ..., Liu Q. *TinyBERT: Distilling BERT for Natural Language Understanding*. Available at: <https://arxiv.org/pdf/1909.10351v5> (accessed 17.03.2025). DOI: 10.48550/arXiv.1909.10351.

Информация об авторах

Петров Сергей Николаевич, кандидат технических наук, доцент, доцент кафедры защиты информации, факультет инфокоммуникаций, Белорусский государственный университет информатики и радиоэлектроники.

E-mail: sergpetrov@inbox.ru
https://www.elibrary.ru/author_profile.asp?authorid=1088896

Мяделец Артем Олегович, учащийся, Национальный детский технопарк.

E-mail: artemmuadzelets@gmail.com

Кундас Елизавета Владимировна, учащийся, Национальный детский технопарк.

E-mail: kundaselizaveta@gmail.com

Information about the authors

Sergei N. Petrov, Ph. D. (Eng.), Assoc. Prof., Assoc. Prof. of the Information Security Department, Faculty of Infocommunications, Belarusian State University of Informatics and Radioelectronics.

E-mail: sergpetrov@inbox.ru
https://www.elibrary.ru/author_profile.asp?authorid=1088896

Artyom O. Myadelets, Student, National Children's Technopark.

E-mail: artemmuadzelets@gmail.com

Elizaveta V. Kundas, Student, National Children's Technopark.

E-mail: kundaselizaveta@gmail.com

УЧЕНЫЕ БЕЛАРУСИ SCIENTISTS OF BELARUS

Старовойтов Валерий Васильевич
(к 70-летию со дня рождения)

Starovoitov Valery Vasilyevich
(on the 70th anniversary of his birth)



6 сентября 2025 г. исполнилось 70 лет доктору технических наук, профессору, ученому в области информатики, главному научному сотруднику лаборатории идентификации систем государственного научного учреждения «Объединенный институт проблем информатики Национальной академии наук Беларусь» (ОИПИ НАН Беларусь) Валерию Васильевичу Старовойтову. Его научные работы стали фундаментом в развитии цифровых технологий анализа изображений и распознавания образов в стране и за ее пределами. Неиссякаемые энергия, знания и опыт Валерия Васильевича помогли взрастить многих аспирантов и молодых специалистов. Труды В. В. Старовойтова получили международное признание, разработанные им новые методы, алгоритмы и подходы широко применяются в различных областях науки и техники.

Биография, научная и педагогическая деятельность. Валерий Васильевич родился 6 сентября 1955 г. в белорусском городе Могилеве. С детства был активным молодым человеком и увлекался спортом. В 1972 г. он окончил школу № 54 г. Минска и поступил на механико-математический факультет Белорусского государственного университета. На последнем курсе проходил практику в Институте технической кибернетики, и с момента окончания университета в 1977 г. и по настоящее время работает в ОИПИ НАН Беларусь. Здесь Старовойтов Валерий Васильевич прошел путь от инженера до главного научного сотрудника института (в этой должности с 2001 г.).

В 1990 г. Валерий Васильевич защитил диссертацию на соискание ученой степени кандидата наук на тему «Математическое и программное обеспечение обработки и отображения двумерных объектов в автоматизированных графических системах» по специальности 05.13.11 «Математическое и программное обеспечение вычислительных машин и систем» (научный руководитель – лауреат Государственных премий СССР и БССР, кандидат технических наук Олег Игнатьевич Семенков) в Институте кибернетики Академии наук Украины (Киев). В 1996 г. получил диплом профессионального инженера Британского института инженеров по электротехнике и электронике (Chartered Engineer (CEng), British Engineering Council, UK). В 1999 г. защитил докторскую диссертацию на тему «Локально-геометрические методы цифровой обработки видеоданных» по специальностям 05.13.16 «Применение вычислительной техники, математического моделирования и математических методов в научных исследованиях» и 05.13.17 «Теоретические основы информатики» в ОИПИ НАН Беларусь. 8 июля 2003 г. ему присвоено звание профессора по специальности «Информатика, управление и вычислительная техника».

С 2000 г. Валерий Васильевич преподавал в должности профессора в ведущих белорусских университетах. Читал курсы лекций, связанные с компьютерной графикой и обработкой изображений, в Китае, Литве, Польше, Узбекистане, Казахстане и других странах в качестве приглашенного профессора. Выполнял исследования в университетах Великобритании, Германии, Греции, Испании, Италии, Турции, Франции.

Особое внимание в своей работе Валерий Васильевич уделяет подготовке научных кадров. Под его научным руководством успешно защищают дипломные и магистерские работы студенты БГУ, БГУИР, БНТУ, подготовлены девять кандидатов наук: Самаль Дмитрий Иванович (2002), Ульд Ахмед Талеб Махфуд (2002), Шумский Иван Петрович (2003), Захаров Игорь Леонидович (2006), Макаров Алексей Олегович (2008), Голуб Юлия Игоревна (2012), Омарова Гульмира Сейхановна (Казахстан, 2023), Ахунджанов Умиджон Юнус угли (2023), Эльдарова Эльмира Эльдар кызы (Казахстан, 2025). Благодаря его руководству многие молодые исследователи смогли определить свой путь в науке и достичь значимых результатов.

Учебные пособия и монографии В. В. Старовойтова стали настольными книгами для студентов, инженеров, научных работников и других специалистов, которые занимаются построением автоматизированных систем обработки и анализа цифровых изображений разной природы.

За свою многолетнюю карьеру Валерий Васильевич руководил многими проектами и внес значительный вклад в развитие информатики, компьютерного зрения и распознавания образов. Под его руководством успешно выполнялись научно-исследовательские и опытно-конструкторские работы, в том числе международные и республиканские проекты, получавшие финансирование от Фонда фундаментальных исследований Беларуси, МНТЦ и ИНТАС.

Профessor уделяет особое внимание исследованиям, направленным на решение актуальных прикладных задач, часто опережая время и предлагая инновационные решения. Его научная деятельность тесно связана с международным сотрудничеством – он активно взаимодействует с зарубежными исследователями, публикуя совместные работы. Такое сотрудничество не только обогащает его научную деятельность, но и способствует интеграции белорусской науки в мировое научное сообщество, повышая ее авторитет на международном уровне.

Валерий Васильевич активно участвует в научно-организационной работе, является членом советов по защите диссертаций, председателем и членом экзаменационных и аттестационных комиссий ведущих белорусских вузов, организатором и участником научных конференций, членом ученого совета ОИПИ НАН Беларуси, членом экспертного совета ВАК Беларуси. Его мнение востребовано при оценке научных проектов и разработок в области информатики и компьютерного зрения. Профессор является членом редколлегий четырех журналов: «Системный анализ и прикладная информатика» и «Труды БГТУ. Серия 4: Принт- и медиатехнологии», Минск, «Проблемы вычислительной и прикладной математики», Ташкент, Eurasian Journal of Mathematical and Computer Applications, Астана (индексируется в Scopus). Валерий Васильевич является также членом Международной ассоциации распознавания образов (International Association for Pattern Recognition, IAPR) и Института инженеров по электротехнике и электронике (Institute of Electrical and Electronics Engineers, IEEE), а также рецензентом нескольких зарубежных журналов: IAPR Newsletter; IEEE Transactions on Systems, Man and Cybernetics, Pattern Recognition, Pattern Recognition Letters, Electronic Imaging, Journal of Intelligent&Robotic Systems, Journal on Applied Signal Processing, Computer Graphics and Machine Vision и ряда белорусских журналов.

В настоящее время Валерий Васильевич активно участвует в разработке систем поддержки принятия решений для медицинской диагностики, занимается исследованиями многоспектральных изображений для решения прикладных задач дистанционного зондирования Земли, в области верификации подписи человека, предлагая новые методы и алгоритмы с целью повышения надежности идентификации.

Научные интересы. Научные интересы Валерия Васильевича охватывают широкий спектр направлений информатики, связанных с решением прикладных задач обработки и анализа цифровых изображений. В их числе: компьютерное зрение, биометрические системы, оценка качества и улучшение изображений, анализ медицинских снимков (включая распознавание патологий), дистанционное зондирование Земли, цифровая картография и геоинформационные системы.

Основные научные результаты. В 1985 г. совместно с Д. И. Винокуровым и В. И. Берейшиком впервые в СССР реализовал пакет интерактивной машинной графики для АРМ-М на основе международного стандарта GKS [1].

В 1990–1991 гг. был главным конструктором системы создания и обновления электронного атласа морских карт (аналог google.maps) по заказу ВМФ СССР.

В 1992 г. совместно с А. В. Старцевым разработал унифицированную систему классификации цифровых картографических данных, представленных национальными картографическими классификаторами [2].

Старовойтов Валерий Васильевич совместно с Д. И. Самалем впервые в мире исследовал задачу сравнения фотографии, отсканированной с паспорта, и фотографии предъявителя этого паспорта в целях автоматизации пограничного контроля [3]. Только через девять лет американские ученые под руководством профессора А. Джайна (A. Jain) начали подобные исследования [4], ссылаясь на статью [3].

Совместно с А. О. Макаровым и И. Л. Захаровым впервые в мире показал возможность повышения разрешения мультиспектральных космических изображений (обычно имеющих разрешение в два или четыре раза ниже панхроматического изображения) до разрешения в 1,5–2 раза выше, чем у панхроматического изображения. Предложенный подход является комбинацией методов паншарпенинга (pansharpening) и суперразрешения (superresolution) [5].

Совместно с Д. И. Самалем и Ю. И. Голуб создал первый белорусский экспериментальный программный комплекс идентификации человека по радужной оболочке глаза [6].

Также В. В. Старовойтовым разработаны локально-геометрический подход к обработке цифровых изображений и модель регулярного дискретного пространства; предложены новые модели одномерных и двумерных текстур для описания и синтеза изображений; теоретически и экспериментально обоснован вариант более точного показателя индекса структурного подобия цифровых изображений равного размера, что является обобщением широко используемого в мире индекса SSIM (победитель конкурса ОИПИ НАН Беларуси на лучший научный результат за 2018 г.); в 2014 г. разработана методика выбора фильтра для сглаживания спекл-шума радарных изображений с синтезированной апертурой; предложен новый подход к оценке результатов классификации несбалансированных данных (почетная грамота за второе место в конкурсе на лучший научный результат ОИПИ НАН Беларуси за 2020 г.); в 2022–2023 гг. предложен новый метод построения одноклассовых классификаторов для распознавания подписей конкретного человека при малом числе образцов [7], а также метод выявления потенциальных микроаневризм (победитель конкурса ОИПИ НАН Беларуси на лучший научный результат за 2022 г.).

В настоящее время основное место работы профессора Валерия Васильевича – ОИПИ НАН Беларуси, стаж научной работы – 48 лет, научно-педагогической деятельности – более 25 лет, опубликовано порядка 200 научных работ, включая пять монографий. Его индекс Хирша по версии scholar.google.com составляет 23, по версии базы данных Scopus – 8. Согласно недельной статистике сайта researchgate.net труды Валерия Васильевича регулярно являются самыми читаемыми среди публикаций сотрудников НАН Беларуси, а несколько раз среди всех белорусских авторов научных публикаций. Самой цитируемой публикацией на английском языке является [8], на русском – [9], а книга [10] скачана только с сайта <https://www.researchgate.net/> более 30 000 раз.

Награды и признание. Научные достижения Валерия Васильевича многократно отмечены наградами и почетными званиями:

- 1984 г. – Грамота Верховного Совета БССР;
- 1990 г. – премия Ленинского комсомола Беларуси в области науки и техники за работу «Разработка и практическое применение средств цифровой обработки сигналов и изображений»;
- 1991 г. – премия Центрального правления Всесоюзного НТО радиотехники, электроники и связи им. Попова для молодых ученых, СССР;



Первый заместитель Председателя
Президиума НАН Беларуси
С. А. Чижик вручает
В. В. Старовойтову нагрудный знак
отличия имени В. М. Игнатовского,
2025 г.

1998 г. – премия НАН Беларуси за лучшую монографию года «Локальные геометрические методы цифровой обработки и анализа изображений», Минск: Ин-т техн. кибернетики АН Беларуси;

2003 г. – лауреат Государственной премии Республики Беларусь в области науки и техники;

2004 г. – несколько почетных грамот (НАН Беларуси, ВАК Беларуси, Министерства образования Республики Беларусь);

2000–2024 гг. – почетные грамоты за лучшие научные результаты в конкурсах ОИПИ НАН Беларуси, благодарность ОИПИ НАН Беларуси за многолетнюю плодотворную и ответственную работу в качестве члена совета по защите диссертаций Д 02.15.01 при БГУИР;

2025 г. – нагрудный знак отличия имени В. М. Игнатовского Национальной академии наук Беларуси за выдающиеся заслуги в развитии науки и укреплении научно-технического потенциала страны.

Юбилей Валерия Васильевича – это повод вспомнить о его заслугах и возможность выразить ему благодарность за вклад в науку, за труд и упорство, силу и новаторские идеи, за умение поддержать и вдохновить на новые свершения не только словом, но и делом. Его многолетняя плодотворная научная деятельность, значительные достижения в области информатики, подготовка научных кадров и активное международное сотрудничество заслуживают глубокого уважения и признания.

Желаем талантливому исследователю и заслуженному ученому Валерию Васильевичу Старовойтову крепкого здоровья, долгих лет жизни, неиссякаемой энергии и творческого вдохновения для воплощения новых научных идей и проектов. Пусть его научная деятельность и дальше способствует развитию информатики в Беларуси и укреплению авторитета белорусской науки в мире.

Список использованных источников

1. ДИФОР-С – пакет интерактивной машинной графики для АРМ-М на основе международного стандарта / авт.-сост. В. И. Берейшик, Д. И. Винокуров, В. В. Старовойтов. – Минск : Ин-т техн. кибернетики АН БССР, 1985. – 142 с.
2. Старцев, А. В. Подход к моделированию и классификации информации банка картографических данных / А. В. Старцев, В. В. Старовойтов // Геодезия и картография. – 1992. – № 8. – С. 48–52.
3. Starovoitov, V. Matching of faces in camera images and document photographs / V. Starovoitov, D. Samal, B. Sankur // Proc. of 2000 Intern. Conf. on Acoustics, Speech and Signal Processing, Istanbul, Turkey, 5–9 June 2000. – Istanbul, 2000. – P. 2349–2352.
4. Bourlai, T. On matching digital face images against scanned passport photos / T. Bourlai, A. Ross, A. Jain // Proc. First IEEE Intern. Conf. Biometrics, Identity and Security (BIDS), Tampa, USA, 22–23 Sept. 2009. – Tampa, 2009. – P. 1–10.
5. Fusion of reconstructed multispectral images / V. Starovoitov, A. Makarau, I. Zakharov, D. Dovnar // Geoscience and Remote Sensing IEEE Symp., Barcelona, Spain, 23–27 July 2007. – Barcelona, 2007. – P. 5146–5149.
6. Голуб, Ю. И. Экспериментальный комплекс программ распознавания личности по радужной оболочке глаза / Ю. И. Голуб, В. В. Старовойтов, Д. И. Самаль // Электроника Инфо. – 2010. – № 5. – С. 65–68.
7. Starovoitov, V. V. A writer-dependent approach to offline signature verification based on one-class support vector machine / V. V. Starovoitov, U. Yu. Akhundjanov // Pattern Recognition and Image Analysis. – 2024. – Vol. 34, no. 2. – P. 340–351.
8. Di Gesù, V. Distance-based functions for image comparison / V. Di Gesù, V. Starovoitov // Pattern Recognition Letters. – 1999. – Vol. 20, no. 2. – P. 207–214.
9. Монич, Ю. И. Оценки качества для анализа цифровых изображений / Ю. И. Монич, В. В. Старовойтов // Искусственный интеллект. – 2008. – № 4. – С. 376–386.
10. Старовойтов, В. В. Цифровые изображения: от получения до обработки / В. В. Старовойтов, Ю. И. Голуб. – Минск : ОИПИ НАН Беларуси, 2014. – 202 с.

Ю. И. Голуб, М. М. Лукашевич, М. М. Татур

ИНФОРМАЦИЯ INFORMATION

УДК 34; 004.8

О правовом регулировании использования и развития технологий искусственного интеллекта

С. В. Кругликов¹, С. Н. Касанин^{1✉}, М. С. Абламейко², Т. Н. Михалева³, Н. С. Минько³

¹*Объединенный институт проблем информатики
Национальной академии наук Беларусь,
ул. Сурганова, 6, Минск, 220012, Беларусь
✉E-mail: s.kasanin@newman.bas-net.by*

²*Белорусский государственный университет,
пр. Независимости, 4, Минск, 220030, Беларусь*

³*Национальный центр законодательства и правовой
информации Республики Беларусь
ул. Берсона, 1а, Минск, 220030, Беларусь*

On legal regulation of the use and development of artificial intelligence technologies

S. V. Kruglikov¹, S. N. Kasanin^{1✉}, M. S. Ablameyko², T. N. Mikhaleva³, N. S. Minko³

¹*The United Institute of Informatics Problems
of the National Academy of Sciences of Belarus,
st. Surganova, 6, Minsk, 220012, Belarus
✉E-mail: s.kasanin@newman.bas-net.by*

²*Belarusian State University,
av. 4 Nezavisimosti, 4, Minsk, 220030, Belarus*

³*National Centre for Legislation and Legal
Information of the Republic of Belarus
st. Berson, 1a, Minsk, 220030, Belarus*

Введение. Развитие цифровизации общества, формирование цифровой экономики в условиях активного совершенствования и использования технологий искусственного интеллекта (ИИ) создают дополнительные возможности и риски, изменяют конфигурацию социальных и правовых отношений. По-иному осуществляется межличностное взаимодействие, переформатируются системы образования и здравоохранения, трудовые и социальные отношения, нематериальные блага. Реализация потенциала систем ИИ способствует изменению моделей государственного управления экономикой, гражданского оборота и др. Современные разработки в сфере ИИ свидетельствуют о возможности их применения в различных предметных областях и отношениях.

Неоднозначно и настороженно ИИ воспринимается в сфере правовых отношений. Большинство исследований отличаются экспериментальным характером, законодательным новациям предшествуют юридические эксперименты, позволяющие подготовить интеграцию ИИ в реальность, например, в сфере беспилотного транспорта. Введение в правовой оборот систем ИИ не может осуществляться в отрыве от социальной и экономической сфер, без учета технических параметров, обеспечения безопасности с взаимодействующими субъектами.

1. Основные подходы и тенденции развития правового регулирования искусственного интеллекта в международных органах, организациях, объединениях, институтах

Организация Объединенных Наций (ООН). Дорожная карта Генерального секретаря ООН по цифровому сотрудничеству: обеспечение глобального руководства по ИИ от 10 июня 2020 г. предусматривает задачи для сотрудничества в сфере ИИ. В 2021 г. выпущено Руководство по стратегиям в области ИИ с ключевыми позициями его стратегического регулирования. Под эгидой ООН в 2023 г. разработаны принципы прозрачности и объяснимости при обработке персональных данных с помощью ИИ. Резолюция Генассамблеи ООН A/78/L.49 «Использование возможностей безопасных, защищенных и надежных систем ИИ для устойчивого развития» от 21 марта 2024 г. предусматривает охрану интеллектуальной собственности.

Всемирная организация здравоохранения (ВОЗ). Принята общая концепция Глобальной стратегии в области цифрового здравоохранения на 2020–2025 гг., подготовлено Руководство по этике и управлению использования ИИ в здравоохранении (2021 г.): намечены перспективы применения ИИ в медицине, минимизации рисков с помощью этических принципов. «Нормативные аспекты использования ИИ в здравоохранении» (2023 г.), Руководство по крупным мультимодальным моделям «Этика и управление ИИ в здравоохранении» (2024 г.) призывают к взвешенному подходу к применению ИИ.

Всемирный банк. Доклад «Использование ИИ в целях создания и развития новой политики и существующего регулирования» (2020 г.) рекомендует разработку дорожной карты (национальной стратегии) с целями в области ИИ, обеспечение этичной, безопасной, ответственной разработки и внедрения ИИ.

ЮНЕСКО. ЮНЕСКО исходит из гибкого подхода к регулированию ИИ. 23 ноября 2021 г. принятая Рекомендация об этических аспектах ИИ – инструмент «мягкого права», не имеющий обязательного характера. Она рассматривает этические аспекты ИИ, дает оценку последствий его применения в сфере образования, науки и коммуникации. Среди базовых принципов формирования национального законодательства: соразмерность, непричинение вреда, безопасность, защищенность, недискриминация, справедливость, устойчивость, прозрачность и др. Подчеркивается важность контроля за ИИ и возложения ответственности. Мягкое управление реализуется при помощи механизмов сертификации, систематического мониторинга, оценки воздействия и др. В 2024 г. разработано руководство ЮНЕСКО по открытым данным для ИИ.

Комиссия ООН по праву международной торговли (ЮНСИТРАЛ). ЮНСИТРАЛ предлагает унифицированный подход к использованию ИИ при заключении договоров; применение в качестве основы Типового закона ЮНСИТРАЛ об электронной торговле (1996 г.) с дополнительной статьей 5 bis, принятой в 1998 г. Юридическая таксономия по вопросам, касающимся цифровой экономики (2023 г.), определяет состав участников системы ИИ.

Организация экономического сотрудничества и развития (ОЭСР). 22 мая 2019 г. утверждены Руководящие принципы ИИ ОЭСР – первые принципы работы с ИИ на межправительственном уровне, закрепившие рекомендации по созданию этичного и недискриминационного ИИ: служение ИИ людям, разработка с учетом требований законодательства, безопасность и др. В 2020 г. запущена онлайн-платформа «Обсерватория политики ИИ ОЭСР».

Европейский союз (ЕС). ЕС придерживается риск-ориентированного подхода. Стратегия развития ИИ и Декларация о сотрудничестве в области ИИ 2018 г. основаны на совершенствовании систем ИИ и доверии общества. Белая книга по ИИ 2020 г. определяет ИИ, подчеркивает преимущества, обозначает риски. Директива об открытых данных 2019 г. предусматривает возможность использования их за плату и безвозмездно. 21 мая 2024 г. принят Закон об ИИ – первый свод правил по ИИ, который регламентирует разработку, внедрение ИИ, запрещает неприемлемые способы использования, проводит категоризацию по уровням риска.

Совет Европы (СЕ). Согласно позиции Специального (временного) комитета СЕ по ИИ (с 2022 г. постоянный комитет по ИИ) регулирование ИИ должно осуществляться на уровне юридически обязывающего документа с фиксацией общих принципов и конкретных правовых норм. Особенность подхода – дифференциация рисков на основе критерии автономности и сложности, прозрачности, объяснимости, проверяемости, устойчивости ИИ, контроль и надзор со стороны человека. Исходя из уровня рисков предусматривается возможность полного (частичного) запрета на применение ИИ и исследования, нарушающие «границу красной зоны». Комитетом министров СЕ 17 мая 2024 г. принята Рамочная конвенция об ИИ и правах человека, демократии и верховенстве права.

Организация по безопасности и сотрудничеству в Европе (ОБСЕ). Стратегический документ «В центре внимания: ИИ и свобода слова» (2020 г.) обозначает риски применения ИИ. Стратегический документ о влиянии ИИ на свободу выражения мнений в политической кампании и выборах 2021 г. рассматривает подходы к решению проблем. Стратегическое руководство 2022 г. определяет рекомендации по применению ИИ в преподнесении информации.

Содружество Независимых Государств (СНГ). 10 марта 2023 г. принятые Рекомендации по нормативному регулированию использования ИИ (дорожная карта), включающие унифицированный подход к формированию правовых и этических норм для стимулирования развития ИИ. Рассматривается возможность установления единой терминологии, требований к безопасности ИИ. 26 октября 2021 г. Правительство Российской Федерации, ряд компаний и научно-исследовательских организаций подписали «Кодекс этики ИИ», носящий рекомендательный характер. В 2025 г. Межпарламентская ассамблея СНГ планирует принять модельный закон «О технологиях ИИ» в целях унификации правил регулирования отношений, в том числе оценки рисков.

Большая семерка (G7). G7 преследует цели гармонизации и стандартизации регулирования в сфере ИИ. Основные документы: Декларация с общими принципами и наставлениями по отношению к разработке и использованию ИИ (опубликована в 2019 г.).

Большая двадцатка (G20). В 2019 г. разработаны Принципы G20 в области развития ИИ, отражающие проблемы развития и внедрения технологии ИИ. В 2021 г. принята Декларация министров цифровых технологий G20 : «Использование цифровых технологий для устойчивого, сильного, инклюзивного подъема экономики». Декларация Большой двадцатки по итогам саммита лидеров G20 (2023 г.) говорит об использовании ИИ на благо общества, снижении рисков.

Деловая двадцатка (B20). В 2017 г. подготовлены рекомендации по поддержке развития человека-ориентированного ИИ. В 2021 г. выпущен Стратегический документ с рекомендациями по уменьшению неравенства, повышению доверия к ИИ.

БРИКС. В стадии проработки находится единый подход к ответственному использованию, контролю, управлению ИИ и минимизации рисков. Приоритетные документы: Меморандум о взаимопонимании по сотрудничеству в области науки, технологий и инноваций (2015 г.), Стратегия экономического партнерства БРИКС (2015 г.), Декларация Гоа (2016 г.), Совместная программа развития и план действия по информационно-коммуникационным технологиям (2016 г.), Инициатива цифрового экономического развития (2017 г.) и др.

Шанхайская организация сотрудничества (ШОС). Утверждена Концепция сотрудничества в сфере цифровизации и информационно-коммуникационных технологий (2019 г.), одобрены План действий по научно-техническому сотрудничеству в приоритетных направлениях на 2022–2025 гг., Программа сотрудничества по развитию ИИ.

2. Опыт иностранных государств в сфере правового регулирования искусственного интеллекта на основе сравнительно-правового анализа. Анализ AI Index законодательных документов 127 стран показывает, что количество законопроектов, содержащих «ИИ», выросло с 1 до 37 в период с 2016 по 2022 г. Анализ парламентских отчетов об ИИ в 81 стране также показывает, что с 2016 г. количество упоминаний ИИ в глобальных законодательных процедурах увеличилось почти в 6,5 раз.

2.1. Стратегическое планирование использования технологий ИИ. В целях стимулирования развития технологий ИИ на государственном уровне принимаются документы стратеги-

ческого характера. Австралия, Швейцария, Вьетнам, Аргентина, Дания стратегическое планирование в области ИИ интегрируют в общие стратегии цифровизации общества, объясняя это тем, что технологии ИИ являются ключевым компонентом продолжающегося процесса цифровизации.

Во многих странах (Бразилия, Германия, Дания, Ирландия, Испания, Канада, Турция, Франция, Эстония, Швеция, Италия, Индия, Индонезия, Аргентина, ОАЭ, Вьетнам, Китай, США) приняты национальные документы стратегического развития ИИ. В некоторых странах, помимо национальной стратегии, приняты такие документы, как Политика по регулированию ИИ – в Великобритании, Концепция развития регулирования отношений в сфере технологий ИИ и робототехники на период до 2024 г. – в Российской Федерации, Стратегический документ по реализации политики в сфере ИИ – в Саудовской Аравии.

Следует отметить, что в ряде стран (Австралия, Нидерланды, Великобритания, Индонезия) приняты планы действий, содержащие инициативы, направленные на развитие ИИ.

2.2. Организационные меры при использовании технологий ИИ. В некоторых странах (Австралия, Бразилия, Россия, Франция, Испания, Канада, Швейцария, Швеция, Вьетнам, Индия, Индонезия, Китай) полномочиями в сфере ИИ наделены уже существующие органы. В Испании учреждена должность Государственного секретаря по цифровизации и ИИ при Министерстве экономики и цифровой трансформации, в ОАЭ – должность Государственного министра по вопросам ИИ.

Многие страны пошли по пути создания отдельных органов (учреждений), которые занимаются вопросами ИИ: в Аргентине – Национальный комитет по этике в науке и технологиях, в Германии – Обсерватория ИИ в сфере работы и общества, в Дании – Датское агентство по цифровизации, в Эстонии – Государственный департамент информационных технологий, в Англии – Управление ИИ, в Китае – Управление по реализации плана ИИ нового поколения, в Италии – Итальянская обсерватория ИИ, в Испании – Обсерватория социального и этического воздействия ИИ, в США – Специальный комитет по ИИ и Национальная комиссия по безопасности ИИ, в Саудовской Аравии – Национальный центр ИИ, в России – Национальный центр развития ИИ при Правительстве Российской Федерации, в Австралии – Национальный центр ИИ.

В некоторых странах созданы консультативные советы по ИИ, которые занимаются реализацией Национальной стратегии ИИ, разработкой рекомендаций по использованию ИИ, координацией деятельности всех заинтересованных сторон, направлением дальнейшей деятельности в сфере ИИ, надзором за применением технологий ИИ (Канада, Испания, ОАЭ, Ирландия, Великобритания, Китай). Также в Великобритании создана Всепартийная парламентская группа по ИИ, в Германии Бундестагом создана Исследовательская комиссия по ИИ, в Израиле – Правительственная группа Стратегии ИИ, в Турции – Национальный руководящий комитет по Стратегии ИИ, во Франции – Федеральная национальная комиссия информационных технологий и свобод, в Ирландии – Консультативный форум по цифровым технологиям в бизнесе, в Индии – Рабочая группа по ИИ.

В рамках государственно-частного партнерства могут создаваться отдельные организации (Германия, Нидерланды, Швеция, Россия, Канада, Новая Зеландия, Испания, Израиль, Вьетнам, Индия, Китай).

Собственным планированием в области ИИ занимаются и местные власти (Бразилия – Буэнос-Айрес, штат Сеара, Китай – Шэнчжэнь, Шанхай).

На международном уровне участниками Глобального партнерства по ИИ являются в общей сложности 44 страны на шести континентах.

2.3. Стандартизация использования технологий ИИ. Вопросам стандартизации уделяется большое внимание на международном уровне. В некоторых странах приняты планы по стандартизации, определяющие направление деятельности в данной сфере (Австралия, Германия, Россия, США, Индия). В ряде стран стандартизация в области ИИ входит в компетенцию уже действующих органов (некоторые из них являются зеркальными комитету ISO/IEC/JTC 1/SC 42) – Австралия, Великобритания, Германия, Дания, Израиль, Ирландия, Испания, Канада, Россия, США, Франция, Эстония, Китай.

2.4. Общее регулирование использования технологий ИИ. Во многих странах предусмотрена возможность тестирования технологий ИИ в рамках «регуляторных песочниц», т. е. создания особого правового режима, позволяющего проводить эксперименты в ограниченной среде. На законодательном уровне такие акты приняты в России, США, ОАЭ.

Наиболее комплексный подход в данной сфере реализован в Германии, где разработаны Стратегия по «регуляторным песочницам», Руководство по «регуляторным песочницам» и предусмотрено «Создание пространства для инноваций».

В Великобритании реализован подход, отличающийся от ЕС в части отказа от межотраслевого законодательства (правила устанавливаются исполнительными органами власти в рамках своей компетенции).

«Регуляторные песочницы» в сфере новых технологий для поддержки инвесторов и компаний, заинтересованных в инновациях, запущены в Саудовской Аравии, Индии, Китае, Эстонии.

«Регуляторные песочницы» в сфере FinTech, целью которых является обеспечение возможности разработки (тестирования) новых технологий и введения их в финансовую сферу, в том числе технологий ИИ, действуют в Швеции, Швейцарии, Саудовской Аравии, Новой Зеландии, Австралии, Нидерландах, Израиле, Италии, Ирландии, Испании, Канаде.

В ряде стран большое внимание уделяется отраслевым «регуляторным песочницам», в частности: в Израиле – дронам, в Канаде – медицине, во Франции – энергетике, в Индии – медицинскому страхованию.

В некоторых странах приняты законодательные акты, направленные на финансирование и поощрение разработки и внедрения ИИ-технологий (Россия, Аргентина, Китай).

Для стимулирования развития технологий ИИ более чем 60 в странах мира применяются инструменты налогового стимулирования в том или ином виде для проведения НИОКР в сфере инноваций, в том числе ИИ, в рамках национального правового режима в Германии, Дании, Нидерландах, Швеции, Эстонии, Швейцарии, Франции, Испании, Италии, Ирландии, Великобритании, США, Канаде, России, Новой Зеландии, Австралии, Аргентине, Вьетнаме, Индии, Китае, ОАЭ.

2.5. Регулирование данных с использованием технологий ИИ.

В сфере регулирования данных есть определенное сходство в части неразглашения персональных данных, неприкосновенности частной жизни, а также процедур обезличивания (анонимизации) для дальнейшего использования при обучении систем ИИ.

Общие правила защиты персональных данных определены в законодательных актах на национальном уровне.

Многие страны уделяют внимание созданию порталов открытых данных для обеспечения эффективной и устойчивой инфраструктуры данных, повышению ответственного использования данных и дальнейшего применения их в области исследований. В некоторых странах (Аргентина (план), Великобритания, Германия, Индонезия) приняты стратегии. Порталы открытых данных функционируют в Австралии, Дании, Ирландии, Эстонии, Швеции, Новой Зеландии, Саудовской Аравии, Канаде, Вьетнаме, Индии, Китае. В США доступ к открытым государственным данным регулируется законами «Об открытых данных» и «О применении ИИ в правительственные структурах».

Прогрессивный подход в данной сфере представлен Израилем – принцип открытости данных «по умолчанию», который обязывает все государственные организации сделать свои наборы данных доступными за исключением тех, которые не могут быть опубликованы в соответствии с ограничениями закона (персональные данные, медицинские данные и т. д.).

На региональном уровне особые условия для разработчиков ИИ в ОАЭ предоставляются только в эмиратах Дубай.

Отдельное внимание во многих странах уделяется вопросам обезличивания/анонимизации данных путем разработки методик/руководств и принципов конфиденциальности (Австралия, Великобритания, Ирландия, Новая Зеландия, США, Китай).

2.6. Регулирование технологий ИИ при использовании в беспилотных автомобилях.

В соответствии с Венской конвенцией о дорожном движении 1968 г., определяющей нормы функционирования дорожно-транспортных систем и стандартизующей правила движения

в странах-участницах (сейчас их 91), контроль над транспортным средством осуществляется человеком. Таким образом, в области регулирования беспилотных транспортных средств можно выделить несколько подходов.

В рамках первого подхода тестирование автономного транспортного средства разрешено только с участием водителя или оператора, который может взять на себя управление в случае необходимости, в том числе использовать функцию дистанционного управления, чтобы иметь возможность осуществлять надлежащий контроль за транспортным средством (Великобритания, Испания, Франция, Австралия, Дания, Ирландия, Канада, Эстония, Швейцария, Швеция).

Отдельно следует выделить страны, в которых регулирование данной сферы определяется на региональном уровне: ОАЭ, США, Китай (испытания проводились в Пекине и Шэньчжэне), Италия (специальные зоны установлены в Парме и Турине), Россия («Иннополис» в Татарстане, «Сколково» в Москве).

В рамках второго подхода проведение испытаний автономных транспортных средств возможно без водителя за рулем, т. е. полностью беспилотная эксплуатация беспилотного автомобиля (Германия, Израиль (только Яндекс, Intel's Mobileye и General Motors), Нидерланды, Новая Зеландия).

2.7. Регулирование использования технологий ИИ в здравоохранении. Одной из приоритетных областей применения ИИ во многих странах является здравоохранение.

В ряде стран программное обеспечение (компьютерная программа) приравнено к медицинским изделиям (устройствам). Такого подхода придерживаются следующие страны: Австралия, Аргентина, Бразилия, Великобритания, Израиль, Индия, Канада, Новая Зеландия, ОАЭ, Швейцария, Индия. В этой связи во многих странах отсутствует специальное регулирование, устанавливающее специальные правила регистрации систем ИИ, в том числе стандарты безопасности, правила проведения клинических испытаний и технических испытаний. В некоторых странах, помимо действующих, принимаются отдельные акты (руководства, планы, правила) в области применения ИИ в медицине (Саудовская Аравия, США, Китай, Россия).

В Европейском союзе страны – участники руководствуются принятymi регламентами и не вводят специального регулирования в отношении систем ИИ, которые содержали бы специальные правила регистрации ИИ в качестве медицинских изделий, в том числе в сфере безопасности и проведения клинических испытаний (Ирландия, Испания, Италия, Дания, Франция, Нидерланды, Швеция, Германия, Эстония).

Отдельная методика анонимизации (обезличивания) медицинских данных в большинстве стран отсутствует. Более углубленный подход в данном вопросе демонстрируют США, Израиль, Италия.

2.8. Регулирование использования технологий ИИ в государственном управлении. В большинстве стран отсутствует специальное законодательство об использовании ИИ в государственном управлении, а возможность применения ИИ в данной сфере предусмотрена на уровне стратегий.

В Ирландии, Испании, Канаде, Нидерландах технологии ИИ активно внедряются в государственном секторе.

В некоторых странах принимаются отдельные документы для применения ИИ в сфере государственного управления: в США утвержден Указ Президента «О содействии использованию надежного ИИ в федеральном правительстве», в Швейцарии – «Рекомендации по ИИ в Конфедерации», в Великобритании – «Руководство по использованию ИИ в государственном секторе», в Италии – «Белая книга «ИИ на службе граждан», в Канаде – «Директива об автоматизированном принятии решений и Программе закупок поставщиков ИИ, прошедших предварительную квалификацию», в Новой Зеландии – «Хартия о применении алгоритмов», в Китае – «Белая книга по безопасности ИИ». Во многих документах отмечается, что ИИ в сфере государственного управления, как и в иных сферах, должен применяться этично и ответственно.

2.9. Этические принципы использования технологий ИИ. Этические принципы, включающие надлежащее развитие, ответственное использование и безопасность функционирования технологий, приняты в Австралии, Великобритании, Испании, Канаде, Нидерландах, Турции, России, Индии, США, Китае.

В некоторых странах учреждены специализированные органы в сфере этики ИИ: Аргентине – Национальный комитет по этике в науке и технике, Германии – Комиссия по этике данных, Франции – Французский национальный пилотный комитет по цифровой этике, Швеции – Комитет по технологическим инновациям и этике, Индонезии – Комиссия по этике.

Примеры отраслевого применения этических правил: Германия – Этические принципы для беспилотного вождения, Индия – Этические рекомендации страны по применению ИИ в биомедицинских исследованиях и здравоохранении.

3. Государственное регулирование в сфере применения технологий ИИ в Республике Беларусь

3.1. Стратегическое планирование. В 2020 г. была принята Национальная стратегия устойчивого развития Республики Беларусь на период до 2035 г. [2]. В рамках данного документа о системах ИИ упоминается в качестве инструмента для цифровизации сфер: здравоохранения; науки, научно-технической и инновационной деятельности; отраслевой структуры экономики; машиностроения (освоение беспилотных транспортных средств и сельхозтехники); сельского хозяйства. Помимо этого, отмечается, что планируется создать национальные стандарты обработки массивов больших данных, сформировать рынок услуг по их обработке на базе инфраструктуры республиканского центра обработки данных и дополнительных платформ.

В 2018 г. была утверждена Стратегия «Наука и технологии: 2018–2040», в рамках которой системы ИИ являются составной частью концептуальной модели «Беларусь интеллектуальная» и входят в группу приоритетов «прорывного» характера [3].

В 2021 г. утверждена Стратегия Республики Беларусь в сфере интеллектуальной собственности до 2030 г. [4]. Согласно данному документу одной из актуальных задач является определение правовой природы созданных ИИ объектов интеллектуальной собственности, а также определение субъектов таких прав. При этом указывается, что с учетом определения право-субъектного статуса ИИ потребуется уточнить ряд законодательно определенных понятий в сфере интеллектуальной собственности («автор», «правообладатель», «права на объекты интеллектуальной собственности» и др.).

В стране действует Государственная программа «Цифровое развитие Беларуси» на 2021–2025 гг. (Программа), утвержденная постановлением Совета Министров Республики Беларусь [5]. Она разработана в соответствии с приоритетными направлениями социально-экономического развития республики до 2025 г. и направлена на внедрение информационно-коммуникационных и передовых производственных технологий в отрасли национальной экономики и сферы жизнедеятельности общества. В рамках Программы предусматривается выполнение мероприятий по созданию (развитию) современной информационно-коммуникационной инфраструктуры, внедрению цифровых инноваций в отраслях экономики и технологий «умных городов», а также обеспечению информационной безопасности таких решений.

Программой социально-экономического развития Республики Беларусь на 2021–2025 гг. [6] для укрепления экономического потенциала предусмотрено развитие производства многофункциональных беспилотных авиационных и роботизированных комплексов, роботизированных систем с использованием технологий ИИ, программно-аппаратных комплексов. Цифровая (виртуальная) инфраструктура будет строиться с применением технологий ИИ, анализа больших данных, виртуальной и дополненной реальности, интернета вещей, робототехнических систем различного функционального назначения и ряда других.

В другой Государственной программе «Инновационное развитие Республики Беларусь» на 2021–2025 гг., утвержденной Указом Президента Республики Беларусь [7], установлено, что в рамках решения задач по формированию и ускоренному развитию научноемких и высокотехнологичных секторов национальной экономики, базирующихся на производствах V и VI технологических укладов, а также закреплению позиций республики на рынках научноемкой продукции необходимо сконцентрировать усилия на разработке роботизированных (коллаборативных) систем с использованием технологий ИИ (в том числе обрабатывающих центров и станков с числовым программным управлением), а также их компонентов (бескорпусные двигатели и сервомоторы).

Разработать и освоить в производстве системы на базе интеллектуальных датчиков и программного обеспечения с элементами ИИ для непрерывного мониторинга оценки состояния и продления долговечности ответственных промышленных и строительных конструкций и сооружений предусмотрено в рамках постановления Совета Министров Республики Беларусь от 23.04.2021 № 245 «О Государственной программе «Наукоемкие технологии и техника» на 2021–2025 годы» [8].

В Концепции информационной безопасности республики, утвержденной постановлением Совета Безопасности Республики Беларусь [9], отмечается, что цифровая трансформация экономики является важнейшей составляющей формирования информационного общества и одним из главных направлений развития Республики Беларусь, в результате которого в ближайшие десятилетия все отрасли, рынки, сферы жизнедеятельности государства должны быть переориентированы на новые цифровые экономические модели. Для решения этой задачи в стране определены структура управления информатизацией и архитектура электронного правительства. Развиваются инновационные цифровые технологии, основанные на системах ИИ, нейронных сетей, обеспечивающие работу с разнообразными информационными ресурсами, в том числе массивами больших данных, методах распределенных вычислений (облачные технологии), технологии реестра блоков транзакций (блокчейн).

В стране сейчас нет отдельного концептуального документа развития регулирования в сфере ИИ. Однако в Концепции правовой политики Республики Беларусь, утвержденной Указом Президента Республики Беларусь № 196, предусмотрено, что необходимо урегулировать вопросы применения ИИ, робототехники и беспилотного транспорта [10].

Технологиям больших данных и ИИ уделено внимание в рамках Концепции развития платежного рынка Республики Беларусь и цифровизации банковского сектора на 2023–2025 гг. [11].

Разработка научно-методического обеспечения образования на всех его уровнях с использованием цифровых платформ, сервисов и инструментов, облачных технологий, виртуальной и дополненной реальности, ИИ предусмотрена в рамках Концепции развития системы образования Республики Беларусь до 2030 г., утвержденной постановлением Совета Министров Республики Беларусь от 30.11.2021 № 683 [12].

На сегодняшний день в республике в области связи и информатизации осуществляют деятельность Министерство связи и информатизации Республики Беларусь ([URL: https://www.mpt.gov.by/ru](https://www.mpt.gov.by/ru)), основными задачами которого являются государственное регулирование, управление деятельностью, реализация государственной политики в сферах информатизации, цифрового развития и связи, формирование условий для эффективного осуществления деятельности и развития организаций всех форм собственности, осуществляющих деятельность в указанных сферах.

В 2015 г. на базе государственного научного учреждения «Объединенный институт проблем информатики Национальной академии наук Беларусь» (ОИПИ НАН Беларусь) и государственного научного учреждения «Институт физиологии Национальной академии наук Беларусь» был создан Межведомственный исследовательский центр ИИ ([URL: http://uiip.bas-net.by/intellekt](http://uiip.bas-net.by/intellekt)). Он объединяет усилия специалистов в области медицинских, биологических, информационных, технологических и физико-математических наук для создания передовых и конкурентоспособных технологий ИИ и создает условия для выполнения научно-исследовательских проектов в области ИИ, реализуемых как в рамках государственных программ научных исследований, так и с привлечением негосударственных инвестиций.

В 2023 г. на базе ОИПИ НАН Беларусь запущена Платформа ИИ BELAI.BY для специалистов и всех заинтересованных исследованиями и разработками в области ИИ ([URL: https://belai.by/ru](https://belai.by/ru)).

Республика Беларусь является государством – участником Содружества Независимых Государств, разработавших Рекомендации по нормативному регулированию использования ИИ, включая этические стандарты для исследований и разработок [13], в которых подчеркивается важность открытости для технологического развития и предусматривается поощрение международной кооперации и сотрудничества в сфере ИИ.

3.2. Нормативно-правовое регулирование в сфере ИИ. В Республике Беларусь отсутствует единый закон, посвященный ИИ. Первые шаги в отношении регулирования национальной ИИ-отрасли предприняты в Декрете Президента Республики Беларусь № 8 «О развитии цифровой экономики» [14], которым, наряду с отнесением ИИ к VI технологическому укладу и созданием беспрецедентных условий правовых и налоговых условий для резидентов Парка высоких технологий, запланировано проведение эксперимента для апробации новых правовых институтов на предмет возможности их имплементации в гражданское законодательство страны. В рамках Декрета предусмотрено осуществление деятельности в сфере ИИ и создания систем беспилотного управления транспортными средствами.

В стране действует Закон № 345-З «О государственно-частном партнерстве» [15], основными задачами которого являются создание условий для обеспечения устойчивого социально-экономического развития и национальной безопасности Республики Беларусь, развитие инновационной деятельности, научноемких производств и повышение уровня производства, совершенствование технологических процессов.

В 2005 г. принят Декрет Президента Республики Беларусь № 12 «О Парке высоких технологий» (Декрет) [16]. Он предусматривает особый правовой режим (так называемую «регуляторную песочницу») для резидентов Парка – организаций, ведущих деятельность в сфере информационно-коммуникационных технологий, в том числе наделяет их правом вести деятельность «в сфере искусственного интеллекта, создания систем беспилотного управления транспортными средствами». В рамках Декрета предусмотрены определенные налоговые льготы для резидентов Парка высоких технологий. Пункт 27 документа устанавливает, что резиденты Парка высоких технологий освобождаются от налога на прибыль (за исключением налога на прибыль, исчисляемого, удерживаемого и перечисляемого при исполнении обязанностей налогового агента), а также от налога на добавленную стоимость по оборотам от реализации товаров (работ, услуг), имущественных прав на территории Республики Беларусь. Помимо этого, в вышеупомянутом Декрете Президента Республики Беларусь № 8 «О развитии цифровой экономики» продлевается срок действия специального правового режима Парка высоких технологий.

Дефиниция термина «искусственный интеллект» содержится в постановлении Совета Министров Республики Беларусь «О мерах по реализации Указа Президента Республики Беларусь от 7 апреля 2022 г. № 136» [17]: «Искусственный интеллект – комплекс технологических решений, позволяющий имитировать когнитивные функции человека (в том числе самообучение и поиск решений без заранее заданного алгоритма) и получать при выполнении конкретных задач результаты, сопоставимые с результатами интеллектуальной деятельности человека, и включающий в себя информационно-коммуникационную инфраструктуру, программное обеспечение, процессы и сервисы по обработке данных и поиску решений».

В образовательных стандартах высшего образования (часть 3 и часть 4), утвержденных и введенных в действие постановлением Министерства образования Республики Беларусь от 30 августа 2013 г. № 88 (в ред. от 14.03.2023) [18] в рамках основных терминов и определений ИИ определяется как «научная дисциплина, объектом которой являются интеллектуальные системы и их формальные модели, а предметом исследования – модели, средства и методы проектирования интеллектуальных систем» (часть 3); «свойство автоматических и автоматизированных систем брать на себя отдельные функции интеллекта человека» (часть 4).

Осуществление научно-исследовательских, опытно-конструкторских и опытно-технологических работ, применение технологий 5G и ИИ предусмотрены в рамках специального правового режима Китайско-Белорусского индустриального парка «Великий камень» в рамках Указа Президента Республики Беларусь от 12.05.2017 № 166 «О совершенствовании специального правового режима Китайско-Белорусского индустриального парка «Великий камень» [19].

В рамках Указа Президента Республики Беларусь от 07.05.2020 № 156 «О приоритетных направлениях научной, научно-технической и инновационной деятельности на 2021–2025 годы» [20] ИИ и робототехника определены в приоритете.

Разработка и внедрение в систему научно-технической информации технологий обработки больших массивов данных, ИИ, виртуальной и дополненной реальности и других современных технологий работы с информацией входят в список мероприятий по развитию национальной

инновационной системы в соответствии с постановлением Совета Министров Республики Беларусь от 15.12.2021 № 722 «О комплексе мероприятий по развитию национальной инновационной системы на 2021–2025 годы» [21].

Регулирование данных. В Республике Беларусь недавно вступил в силу Закон № 99-3 «О защите персональных данных» (Закон) [22], направленный на обеспечение защиты персональных данных, прав и свобод физических лиц при обработке их персональных данных. Он содержит правовую категорию обезличенных данных, которыми являются действия, в результате их становится невозможным без использования дополнительной информации определить принадлежность персональных данных конкретному субъекту.

В Законе установлено, что обработка персональных данных допускается без согласия субъекта в научных или иных исследовательских целях при условии обязательного обезличивания персональных данных при одновременном соблюдении следующих условий:

- обработка персональных данных осуществляется в научных или иных исследовательских целях;
- персональные данные обезличены.

В посттатейном комментарии к Закону, разработанном Национальным центром защиты персональных данных Республики Беларусь, указывается: «по сути, рассматриваемое основание является способом найти баланс между необходимостью развития новых технологий (большие данные, искусственный интеллект и др.), требующих обработки массивов персональных данных для создания новых сервисов и др., и требованиями законодательства о персональных данных» [23].

В соответствии с Приказом Оперативно-аналитического центра при Президенте Республики Беларусь № 195 «О технической и криптографической защите персональных данных» [24] утверждены методы обезличивания персональных данных. Для обезличивания персональных данных собственники (владельцы) информационных систем могут использовать следующие методы: введение идентификаторов, изменение состава, декомпозицию, перестановку и зашифрование.

Законодательством в области защиты персональных данных прямо не установлены ограничения возможности использования автоматизированных систем при обработке персональных данных.

Регулирование беспилотных автомобилей. Специальное регулирование автоматизированных транспортных средств в стране отсутствует. Целевой функцией Комплексной программы развития электротранспорта на 2021–2025 гг., утвержденной постановлением Совета Министров Республики Беларусь от 09.04.2021 № 213 «О Комплексной программе развития электротранспорта на 2021–2025 годы» [25], определено создание нового сектора машиностроительной отрасли на основе внедрения высоких информационно-коммуникационных технологий и ИИ.

В вышеупомянутом Декрете № 12 Республики Беларусь предусмотрено, что в качестве резидентов Парка высоких технологий могут быть зарегистрированы юридические лица и индивидуальные предприниматели Республики Беларусь, планирующие осуществлять разработку, обслуживание, эксплуатацию и реализацию систем беспилотного управления транспортными средствами.

Для реализации государственной политики в области дорожного движения предусмотрена разработка концепции обеспечения безопасности дорожного движения на дорогах с участием высокоавтоматизированных (беспилотных) транспортных средств, что отражено в Концепции обеспечения безопасности дорожного движения в Республике Беларусь, утвержденной постановлением Совета Министров Республики Беларусь от 22.05.2023 № 329 [26]. В рамках постановления Совета Министров Республики Беларусь от 25.10.2022 № 724 «О порядке функционирования интеллектуальных транспортных систем» [27] рассматривается обеспечение условий для внедрения систем активной безопасности, самодиагностики и поддержки водителя, высокоавтоматизированных и полностью автоматизированных (беспилотных) транспортных средств.

Кроме того, Республика Беларусь является участницей Венской конвенции 1968 г. «О дорожном движении» [28], где статьей 8 установлено, что каждое транспортное средство или состав транспортных средств, которые находятся в движении, должны иметь водителя.

3.3. Этическое регулирование. В Республике Беларусь нет специальных документов, посвященных вопросам этики в сфере ИИ. Ряд белорусских организаций присоединился к Кодексу этики в сфере искусственного интеллекта (в 2022 г. Сбер Банк (Беларусь); в 2023 г. Объединенный институт проблем информатики НАН Беларуси, ООО «БЕЛФИН», Институт информационных технологий Белорусского государственного университета информатики и радиоэлектроники, Полесский государственный университет) (URL: https://a-ai.ru/?page_id=2128).

3.4. Нормативно-техническое регулирование. Положения законодательства, касающиеся нормативно-технического регулирования ИИ, в настоящее время в стороне отсутствуют. В СТБ 2583-2020 «Цифровая трансформация. Термины и определения» [29] технологии ИИ упоминаются в рамках дефиниций терминов «аналитика больших данных» и «цифровые инновации».

Постановление Государственного комитета по стандартизации Республики Беларусь от 12.02.2024 №10 «Об утверждении, введении в действие, отмене и изменении технических нормативных правовых актов» [30]. Данным Постановлением в Приложение 2 приведен Перечень правил ООН, предварительных национальных стандартов Российской Федерации, национальных стандартов Российской Федерации, национальных стандартов Республики Казахстан, вводимых в действие с 1 мая 2024 г. в качестве государственных стандартов Республики Беларусь:

ГОСТ Р 70249-2022 «Системы искусственного интеллекта на автомобильном транспорте. Высокоавтоматизированные транспортные средства. Термины и определения»;

ГОСТ Р 70250-2022 «Системы искусственного интеллекта на автомобильном транспорте. Варианты использования и состав функциональных подсистем искусственного интеллекта»;

ГОСТ Р 70251-2022 «Системы искусственного интеллекта на автомобильном транспорте. Системы управления движением транспортным средством. Требования к испытанию алгоритмов обнаружения и распознавания препятствий»;

ГОСТ Р 70252-2022 «Системы искусственного интеллекта на автомобильном транспорте. Системы управления движением транспортным средством. Требования к испытанию алгоритмов низкоуровневого слияния данных»;

ГОСТ Р 70253-2022 «Системы искусственного интеллекта на автомобильном транспорте. Системы управления движением транспортным средством. Требования к испытанию алгоритмов обнаружения и реконструкции структуры перекрестков»;

ГОСТ Р 70254-2022 «Системы искусственного интеллекта на автомобильном транспорте. Системы управления движением транспортным средством. Требования к испытанию алгоритмов прогнозирования поведения участников дорожного движения»;

ГОСТ Р 70255-2022 «Системы искусственного интеллекта на автомобильном транспорте. Системы управления движением транспортным средством. Требования к испытанию алгоритмов обнаружения и распознавания дорожных знаков»;

ГОСТ Р 70256-2022 «Системы искусственного интеллекта на автомобильном транспорте. Системы управления движением транспортным средством. Требования к испытанию алгоритмов контроля обочины и полосы движения».

Заключение. Правовое регулирование разработки и использования ИИ осуществляется на универсальном, региональном, национальном уровнях.

Анализ актов международных организаций, межгосударственных образований позволяет вывести ряд общих принципов и тенденций в регулировании отношений в области ИИ:

- антропоцентричный подход, приоритет прав и интересов человека;
- внимание этическим аспектам ИИ;
- позиционирование носителей ИИ в качестве инструмента, объекта;
- ответственность разработчиков и собственников за действия носителей ИИ;
- риск-ориентированный подход в сфере ИИ.

Изучение зарубежного опыта регулирования в сфере ИИ позволило выявить следующие модели:

– регулирования специальными актами стратегического планирования развития ИИ (Китай, Россия, Франция и др.);

– отраслевого регулирования с тенденцией комплексного регулирования в сфере ИИ (Южная Корея);

– гибридную модель, которая сочетает стратегическое и отраслевое регулирование (США).

Также используется регулирование посредством рекомендательных и технических актов, установления экспериментальных правовых режимов («регуляторные песочницы»).

Изучение зарубежного опыта позволило выявить следующие тенденции, которые целесообразно учитывать: определение регулятора в сфере ИИ, определение стратегии развития ИИ; формирование общей концепции и отраслевого правового регулирования ИИ.

В Республике Беларусь в настоящее время не принят специальный правовой акт, комплексно регламентирующий сферу ИИ. Однако в ряде стратегических и программных актов указано на то, что использование ИИ в различных сферах отвечает национальным интересам нашей страны, характеризуется как приоритет инновационного развития. В отраслевых актах (например, в сфере образования, электротранспорта) все более активно употребляются термины, связанные с технологиями ИИ.

Для закрепления единых подходов к формированию и реализации государственной политики в отношении внедрения технологий ИИ, определения приоритетных направлений развития в области ИИ, использования в качестве методологической основы для разработки документов стратегического планирования и актов отраслевого значения в обозначенной сфере предлагается разработка *Концепции правового регулирования технологий искусственного интеллекта* (по аналогии с принятыми в Республике Беларусь Концепцией правовой политики Республики Беларусь, утвержденной Указом Президента Республики Беларусь от 28 июня 2023 г. № 196; Концепцией государственной кадровой политики Республики Беларусь, утвержденной Указом Президента Республики Беларусь от 3 января 2024 г. № 1, и др.).

В Концепции правового регулирования технологий ИИ предлагается отразить:

- основные термины и определения;
- цели и задачи государственной политики в сфере ИИ;
- принципы регулирования отношений в сфере ИИ;
- современное состояние системы общественных отношений в Республике Беларусь, затрагиваемых внедрением ИИ;
- специфику трансформации общественных отношений под влиянием ИИ и тенденции развития ИИ в мировом контексте;
- общие подходы к формированию правовой политики в сфере ИИ с учетом национальных интересов в обозначенной области;
- приоритетные направления (сфера медицины, образования, труда, транспорта) и механизмы правового обеспечения развития технологий ИИ, включая меры стимулирования;
- основные угрозы, вызовы, риски использования ИИ и пути их нейтрализации, в том числе в контексте национальной безопасности.

Интенсивное развитие технологий ИИ и их влияние на общественные отношения создают необходимость доктринальной проработки и правовой регламентации вопросов кибербезопасности и ответственности в правоотношениях, связанных с использованием ИИ.

Организационно-правовой механизм регламентации и координации деятельности в сфере ИИ может быть реализован в рамках существующей системы органов государственного управления и иных организаций.

Список использованных источников

1. Глобальный атлас регулирования искусственного интеллекта. Вектор БРИКС : 3-е изд., перераб. и дополн.; под общ. ред. А. В. Незнамова. – М. : ООО «Профсуvenir», 2023 – 452 с.
2. Национальная стратегия устойчивого развития Республики Беларусь на период до 2035 года : протокол засед. Президиума Совета Министров Респ. Беларусь от 4 февр. 2020 г. № 3. –

URL: <https://economy.gov.by/uploads/files/Natsionalnaja-strategija-ustojchivogo-razvitiya-Respubliki-Belarus-na-period-do-2035-goda.pdf> (дата обращения: 19.08.2024).

3. Стратегия «Наука и технологии: 2018–2040 : постановление Президиума Нац. акад. наук Беларусь от 26 февр. 2018 г. № 17. – URL: https://nasb.gov.by/reference/razvitie/strateg2018_2040.pdf (дата обращения: 19.08.2024).

4. О Стратегии Республики Беларусь в сфере интеллектуальной собственности до 2030 года : постановление Совета Министров Респ. Беларусь от 24 нояб. 2021 г. № 672 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=12551&p0=C22100672&p1=1> (дата обращения: 19.08.2024).

5. О Государственной программе «Цифровое развитие Беларусь» на 2021–2025 годы : постановление Совета Министров Респ. Беларусь от 02 февр. 2021 г. № 66 // ЭТАЛОН : информ.-поисковая система. – URL: https://etalonline.by/document/?regnum=C22100066#Заг_Утв_1 (дата обращения: 19.08.2024).

6. Об утверждении Программы социально-экономического развития Республики Беларусь на 2021–2025 годы : Указ Президента Респ. Беларусь от 29 июля 2021 г. № 292 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=11031&p0=P32100292> (дата обращения: 19.08.2024).

7. О Государственной программе инновационного развития Республики Беларусь на 2021–2025 годы : Указ Президента Респ. Беларусь от 15 сент. 2021 г. № 348 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=3871&p0=P32100348> (дата обращения: 19.08.2024).

8. О Государственной программе «Наукоемкие технологии и техника» на 2021–2025 годы : постановление Совета Министров Респ. Беларусь от 23 апреля 2021 г. № 245 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=11031&p0=C22100245> (дата обращения: 19.08.2024).

9. О Концепции информационной безопасности Республики Беларусь : постановление Совета Безопасности Респ. Беларусь от 18 марта 2019 г. № 1 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=3871&p0=P219s0001> (дата обращения: 19.08.2024).

10. О концепции правовой политики Республики Беларусь : Указ Президента Респ. Беларусь от 28 июня 2023 г. № 196 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=3871&p0=P32300196> (дата обращения: 19.08.2024).

11. Концепция развития платежного рынка Республики Беларусь и цифровизации банковского сектора на 2023–2025 годы : постановление Правления Нац. банка Респ. Беларусь 27 июля 2023 г. № 267. – URL: https://www.nbrb.by/payment/koncepcija-rasvitija-platioznogo-rinka_2023-2025.pdf (дата обращения: 19.08.2024).

12. О Концепции развития системы образования Республики Беларусь до 2030 года : постановление Совета Министров Респ. Беларусь от 30 нояб. 2021 г. № 683 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://adu.by/images/2021/12/koncep-razv-sist-obrazov.pdf> (дата обращения: 19.08.2024).

13. Рекомендации по нормативному регулированию использования искусственного интеллекта, включая этические стандарты для исследований и разработок // Межпарламентская Ассамблея государств – участников Содружества Независимых Государств. – URL: https://iacis.ru/baza_dokumentov/modelnie_zakonodatelnie_akti_i_rekomendacii_mp_a_sng/rekomendacii (дата обращения: 19.08.2024).

14. О развитии цифровой экономики : Декрет Президента Респ. Беларусь от 21 дек. 2017 г. № 8 // Официальный Интернет-портал Президента Респ. Беларусь. – URL: https://president.gov.by/ru/documents/dekret-8-ot-21-dekabrja-2017-g-17716?TSPD_101_R0=08eaff62760ab2000e0bd30a63e10b0bd52d614a0fb02757db8494732bbedf51c0dd5ddd25f272f6a0881bee00a14300035991adbe5ac1adcabb25ae0fd63bcc94500d0859864807743202b3a4677087312fb2890815d2621a080fd51b785bd51 (дата обращения: 19.08.2024).

15. О государственно-частном партнерстве : Закон Респ. Беларусь от 30 дек. 2015 г. № 345-3 – URL: <https://economy.gov.by/uploads/files/G4P/Zakon-Respubliki-Belarus-o-GChP-2.pdf> (дата обращения: 19.08.2024).

16. О Парке высоких технологий : Декрет Президента Респ. Беларусь от 22 сент. 2005 г. № 12 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=3871&p0=pd0500012>. – Дата доступа: 19.08.2024.

17. О мерах по реализации Указа Президента Республики Беларусь от 7 апр. 2022 г. № 136 : постановление Совета Министров Республики Беларусь от 21 апр. 2023 г. № 280 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=12551&p0=C22300280> (дата обращения: 19.08.2024).

18. Об утверждении, введении в действие образовательных стандартов высшего образования : постановление Министерства образования Респ. Беларусь от 30 авг. 2013 г. № 88 // ЭТАЛОН : информ.-

поисковая система. – URL: <https://etalonline.by/document/?regnum=W21328044p> (дата обращения: 19.08.2024).

19. О совершенствовании специального правового режима Китайско-Белорусского индустриального парка «Великий камень» : Указ Президента Респ. Беларусь от 12 мая 2017 г. № 166 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=3961&p0=P31700166> (дата обращения: 19.08.2024).

20. О приоритетных направлениях научной, научно-технической и инновационной деятельности на 2021–2025 годы : Указ Президента Респ. Беларусь от 07 мая 2020 г. № 156 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=11031&p0=P32000156> (дата обращения: 19.08.2024).

21. О комплексе мероприятий по развитию национальной инновационной системы на 2021–2025 годы : постановление Совета Министров Респ. Беларусь от 15 дек. 2021 г. № 722 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=11031&p0=C22100722> (дата обращения: 19.08.2024).

22. О защите персональных данных : Закон Респ. Беларусь от 07 мая 2021 г. № 99-3 // Национальный правовой Интернет-портал Республики Беларусь. – URL: https://pravo.by/upload/docs/op/H12100099_1620939600.pdf (дата обращения: 19.08.2024).

23. Постатейный комментарий к Закону Республики Беларусь «О защите персональных данных» / А. А. Гаев, В. И. Диско, С. В. Задиран [и др.] // Нац. центр защиты персональных данных Респ. Беларусь. – URL: <https://cpd.by/pravovaya-osnova/metodologicheskiye-dokumenty-rekomendatsii/postatejnuyu-kommentarij-k-zakonu-respublik-i-belarus-o-zashhite-personalnyh-danniyh/> (дата доступа: 19.08.2024).

24. Методы обезличивания персональных данных : приложение 5 к Положению о порядке технической и криптографической защиты информации в информационных системах, предназначенных для обработки информации, распространение и (или) предоставление которой ограничено (в редакции приказа Оперативно-аналитического центра при Президенте Республики Беларусь 12.11.2021 № 195) // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://www.oac.gov.by/public/content/files/files/law/prikaz-oac/2021-195.pdf> (дата обращения: 19.08.2024).

25. О Комплексной программе развития электротранспорта на 2021–2025 годы : постановление Совета Министров Респ. Беларусь от 09 апр. 2021 г. № 213 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=11031&p0=C22100213> (дата обращения: 19.08.2024).

26. О Концепции обеспечения безопасности дорожного движения в Республике Беларусь : постановление Совета Министров Респ. Беларусь от 22 мая 2023 г. № 329 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=3961&p0=C22300329> (дата обращения: 19.08.2024).

27. О порядке функционирования интеллектуальных транспортных систем : постановление Совета Министров Респ. Беларусь от 25 окт. 2022 г. № 724 // Национальный правовой Интернет-портал Республики Беларусь. – URL: <https://pravo.by/document/?guid=3961&p0=C22200724> (дата доступа: 19.08.2024).

28. Конвенция о дорожном движении (с изм. от 28.09.2004) (вместе с "Техническими условиями, касающимися автомобилей и прицепов") (Заключена в г. Вене 08.11.1968) (с изм. и доп. от 03.03.1992) // КонсультантПлюс. Россия : справ. Правовая система. – URL: <https://www.ptiafond.ru/files/konvenciya-1968-vena.pdf> (дата обращения: 19.08.2024).

29. Цифровая трансформация. Термины и определения : СТБ 2583-2020. Введ. 01.03.2021. – Минск : Госстандарт : Белорус. гос. ин-т стандартизации и сертификации, 2021. – III, 11 с.

30. Об утверждении, введении в действие, отмене и изменении технических нормативных правовых актов : постановление Гос. комитета по стандартизации Респ. Беларусь от 12 февр. 2024 г. № 10 // ЭТАЛОН : информ.-поисковая система. – URL: https://etalonline.by/document/?regnum=w224p0003&q_id (дата обращения: 19.08.2024).

Правила для авторов

Редакция журнала «Информатика» просит авторов руководствоваться приведенными ниже правилами.

I. Статьи принимаются в редакцию через электронную систему подачи по адресу <http://inf.grid.by> в формате файлов текстовых редакторов Microsoft Word. Объем оригинальной статьи – от 8 до 16 стр., включая рисунки, таблицы и достаточное количество наиболее актуальных ссылок; объем обзорной статьи – от 16 до 32 стр., включая все основные ссылки. Текст набирается с переносами, шрифт Times New Roman 11 пт, интервал между строками одинарный, абзацный отступ 0,5 см, поля по 2,5 см со всех сторон.

Материал статьи должен быть четко структурированным: Введение; основные разделы, в которых изложены цели и задачи, методы, результаты; Заключение (выводы).

II. Статьи о результатах работ, проведенных в научных учреждениях, должны иметь разрешение на публикацию (сопроводительное письмо за подписью руководителя или выписку из заседания ученого совета, отдела или кафедры, акт экспертизы).

III. Статьи в обязательном порядке должны включать аннотацию, ключевые слова, список литературы, информацию об авторах на русском и английском языках.

На заглавной странице располагаются следующие метаданные:

1. Индекс по универсальной десятичной классификации (УДК); на русском и английском языках тип статьи (оригинальная или обзорная), название статьи, инициалы и фамилии всех авторов, полное наименование учреждений, где работают авторы, с указанием почтового адреса, при наличии указывается ученая степень и ORCID, e-mail ответственного лица.

2. Аннотация (Abstract) объемом 150–250 слов в оригинальной статье должна быть структурирована отдельными подразделами: Цели, Методы, Результаты, Заключение, а также максимально характеризовать содержательную часть рукописи. Сюда не следует включать впервые введенные термины, аббревиатуры (за исключением общезвестных), ссылки на литературу.

3. Ключевые слова (Keywords) – наиболее значимые слова или словосочетания по теме работы, отражающие специфику темы, объекты и результаты исследования; перечень ключевых слов должен содержать 5–10 слов.

4. В разделе Благодарности (Acknowledgements) указываются все источники финансирования исследования, а также благодарности людям, которые участвовали в работе над статьей.

5. Автор обязан уведомить редакцию о реальном или потенциальном конфликте интересов, включив информацию в раздел Конфликт интересов (Conflict of interest).

6. Формулы, рисунки, таблицы в статье нумеруются в соответствии с порядком их упоминания в тексте. Ссылки на рисунки и таблицы в тексте обязательны. Рисунки должны быть выполнены с хорошим разрешением в масштабе, позволяющем четко различать надписи и обозначения. Цветные иллюстрации печатаются только в том случае, когда это необходимо для понимания излагаемого материала. Подрисуночные подписи с расшифровкой всех позиций, представленных на рисунке, и названия таблиц набираются шрифтом гарнитуры основного текста размером 9 пт. Перевод подрисуночной подписи и пояснений к рисунку, а также перевод названия таблицы, заголовки строк или столбцов располагаются курсивом после русскоязычной версии.

7. Набор формул выполняется в формульном редакторе Microsoft Equation или Math Type. Прямыми шрифтом набираются: греческие и русские буквы; математические символы (\sin , \lg , ∞); символы химических элементов (C, Cl, CHCl₃); цифры (римские и арабские); индексы (верхние и нижние), являющиеся сокращениями слов. Курсивом набираются латинские буквы, символы физических величин (в том числе и в индексе).

8. Список использованной литературы оформляется в соответствии с требованиями Высшей аттестационной комиссии Республики Беларусь (ГОСТ 7.5–2008). Номер литературной ссылки в тексте дается порядковым номером в квадратных скобках. Ссылаясь на неопубликованные работы не допускается.

9. Отдельно оформляется References со следующей структурой: авторы (транслитерация), транслитерированное название монографии, *Перевод названия монографии на английский язык*. Выходные данные с обозначениями на английском языке. От транслитераций названий статей можно отказаться.

10. Ссылки на учебно-методическую литературу, ГОСТы, авторефераты, статистические отчеты в список не включаются, а оформляются в виде сносок (с подробными рекомендациями можно ознакомиться на сайте журнала в разделе Правила для авторов).

11. В разделе Информация об авторах (Information about the authors) приводятся ФИО авторов полностью, ученая степень, звание, должность, название организации, ORCID (при наличии).

IV. Все поступающие в редакцию рукописи проходят предварительную проверку на соответствие Правилам для авторов. Статья может быть возвращена автору на доработку с просьбой устранить недостатки или дополнить информацию. После проверки на соответствие правилам статья направляется рецензенту с указанием сроков рецензирования.

V. При наличии замечаний рецензента автору предоставляется определенное время на доработку рукописи. Статьи, направляемые на доработку, должны быть возвращены в исправленном виде с ответами на все замечания. Окончательное решение о публикации или отклонении рукописи принимается редакцией журнала. При положительном заключении рецензента статья передается редактору для подготовки к печати. Редакция оставляет за собой право на редакционные изменения, не искажающие основное содержание статьи.

VI. Редакция журнала предоставляет возможность первоочередного опубликования статей, представленных лицами, которые осуществляют послевузовское обучение (аспирантура, докторантуре, соискательство) в год завершения обучения.

VII. Авторы несут ответственность за направление в редакцию статей, уже опубликованных ранее или принятых к публикации другими изданиями.

ИНДЕКСЫ

00827

для индивидуальных
подписчиков

008272

для предприятий
и организаций

3 | 2025

TOM ■ VOL. 22

ИНФОРМАТИКА ■ INFORMATICS

ISSN 1816-0301 (Print)



9 771816 030000