

# ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ, МЕХАНИКИ И ОПТИКИ

2024, ТОМ 24, НОМЕР 5 (СЕНТЯБРЬ–ОКТЯБРЬ)

ISSN 2226-1494 (PRINT), 2500-0373 (ONLINE)

**ОБЗОРНЫЕ СТАТЬИ**

Автоматический сурдоперевод: обзор нейросетевых методов распознавания и синтеза звучащей и жестовой речи

Обзор алгоритмов маршрутизации для сетей на кристалле

**ОПТИЧЕСКИЕ СИСТЕМЫ И ТЕХНОЛОГИИ**

Исследование характеристики полупроводникового лазерного диода с распределенной обратной связью в режиме источника и приемника оптического излучения для регистрации отклика волоконных решеток Брэгга

Исследование усилительных свойств активных областей на основе  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  сверхрешеток, используемых для вертикально-излучающих лазеров

Изменение оптических свойств поверхности серебра за счет лазерного структурирования

Алгоритм ориентирования на местности беспилотных летательных аппаратов с использованием машинного зрения

Разработка волоконно-оптической системы для мониторинга геотехнических сооружений

**АВТОМАТИЧЕСКОЕ УПРАВЛЕНИЕ И РОБОТОТЕХНИКА**

Управление нелинейными объектами с гарантией нахождения регулируемой переменной в заданном множестве при возмущениях и помехах в измерениях

**НОВЫЕ МАТЕРИАЛЫ И НАНОТЕХНОЛОГИИ**

Влияние качества растворителя на трибологические свойства полимерных щеток

**КОМПЬЮТЕРНЫЕ СИСТЕМЫ И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ**

Совместное распознавание акустических сцен и аудиособытий с помощью многозадачного обучения компактных моделей

Метод оптимизации нейронных сетей на основе структурной дистилляции с применением генетического алгоритма

ViSL model: модель автоматической генерации предложений вьетнамского языка жестов (на англ.яз.)

Расширенное обнаружение аномалий в сетевой безопасности: комплексный ансамблевый подход (на англ.яз.)

Усовершенствование контроля доступа на основе атрибутов с помощью технологий Ethereum и ZK-SNARK (на англ.яз.)

Сравнительный анализ нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам

Гарантированные оценки гамма-процентного остаточного ресурса оборудования систем хранения данных

Классификация поражений рассеянным склерозом посредством анализа изображений магнитно-резонансной томографии методом глубокого обучения (на англ.яз.)

Создание и анализ многомодального корпуса данных для автоматического распознавания агрессивного поведения людей

Трехмерная реконструкция отдельных изображений с помощью бинарного классификатора (на англ.яз.)

Обнаружение скрытого вредоносного программного обеспечения с использованием глубокой нейронной сети с выбором признаков ANOVA на наборе данных CIC-MalMem-2022 (на англ.яз.)

**МАТЕМАТИЧЕСКОЕ И КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ**

Карта намагничивания вентильно-индукторного электродвигателя: экспериментальный подход

**КРАТКИЕ СООБЩЕНИЯ**

Спектральная зависимость квантовой эффективности фотоэлектрохимического разложения воды нанопористыми слоями серебра

<i>Иванько Д.В., Рюмин Д.А.</i>	669
<i>Бондаренко М.И., Платунов А.Е.</i>	687
<i>Ошлаков В.С., Алейник А.С., Волковский С.А., Смирнов Д.С.</i>	699
<i>Копытов П.Е., Андрюшкин В.В., Пирогов Е.В., Соболев М.С., Бабичев А.В., Шерняков Ю.М., Максимов М.В., Лютецкий А.В., Пихтин Н.А., Каракинский Л.Я., Новиков И.И., Си-Конг Тиан, Егоров А.Ю.</i>	709
<i>Морозова А.А., Капустина У.А., Лутошина Д.С., Романова Г.В.</i>	717
<i>Зикратов И.А., Беляев П.Ю., Неверов Е.А.</i>	726
<i>Никулин И.Л., Рофер Ю.И.</i>	738
<i>Вэнь С., Фуртат И.Б.</i>	745
<i>Лукиев И.В., Михайлов И.В., Борисов О.В.</i>	751
<i>Сурков М.К.</i>	758
<i>Кузьмин В.Н., Менисов А.Б., Сабиров Т.Р.</i>	770
<i>Данг Х., Бессмертный И.А.</i>	779
<i>Пандей Р., Пандей М., Назаров А.Н.</i>	788
<i>Маалла М., Беззатеев С.В.</i>	797
<i>Мельников А.В., Полищук Ю.М., Русанов М.А., Аббазов В.Р., Кочергин Г.А., Куприянов М.А., Байсалымова О.А., Соколов О.И.</i>	806
<i>Ломакин М.И., Докукин А.В., Олтян И.Ю., Ниязова Ю.М.</i>	815
<i>Дивья М., Дхилитан Дж., Сараванан А.</i>	824
<i>Узяев М.Ю., Карпов А.А.</i>	834
<i>Ресен С.А.</i>	843
<i>Хаджила М., Мерзуг М., Ферхи В., Муссаян Д., Буйден А.Б., Хашеми М.Х.</i>	849
<i>Яременко А.М., Демидова Г.Л., Сорокина А.А., Маматов А.Г., Богданов А.Н., Анучин А.С.</i>	858
<i>Сидоров А.И., Нащекин А.В., Никоноров Н.В.</i>	866

**Главный редактор — В.О. Никифоров**, д.т.н., профессор

#### РЕДАКЦИОННАЯ КОЛЛЕГИЯ

**Беззатеев С.В.** — д.ф.-м.н., доцент (Россия)  
**Беликов А.В.** — д.ф.-м.н., профессор (Россия)  
**Бессмертный И.А.** — д.т.н., профессор (Россия)  
**Бобцов А.А.** — д.т.н., профессор (Россия)  
**Бухановский А.В.** — д.т.н. (Россия)  
**Волков К. Н.** — д.ф.-м.н. (Великобритания)  
**Дукельский К.В.** — д.т.н., доцент (Россия)  
**Ефимов Д.В.** — PhD (Франция)  
**Заколдаев Д.А.** — к.т.н., доцент (Россия)  
**Иорш И.В.** — д.ф.-м.н. (Россия)  
**Кармановский Н.С.** (заместитель главного редактора) — к.т.н., доцент (Россия)  
**Комаров И.И.** — к.ф.-м.н., доцент (Россия)  
**Матвеев Ю.Н.** — д.т.н. профессор (Россия)  
**Никоноров Н.В.** — д.ф.-м.н., профессор (Россия)  
**Полищук Г.С.** — к.т.н. (Россия)  
**Романов А.Е.** — д.ф.-м.н., профессор (Россия)  
**Сидоркина И.Г.** — д.т.н., профессор (Россия)  
**Степанов О.А.** — д.т.н., профессор (Россия)  
**Татарникова Т.М.** — д.т.н., доцент (Россия)  
**Тимофеев А. В.** — д.т.н. (Казахстан)  
**Успенская М.В.** — д.т.н., профессор (Россия)  
**Цыпкин А.Н.** — д.ф.-м.н. (Россия)

**Ответственный секретарь — И.В. Малькова**

Учредитель: Университет ИТМО  
Издание зарегистрировано в Федеральной службе по надзору в сфере связи, информационных технологий и массовых коммуникаций (свидетельство ПИ №ФС77-67990 от 6 декабря 2016 г.).

Языки журнала: русский, английский.

ISSN 2226-1494 (print version), ISSN 2500-0373 (online version)

Англоязычное название: «Scientific and Technical Journal of Information Technologies, Mechanics and Optics». Транслитерированное название: «Nauchno-Tekhnicheskii Vestnik Informatsionnykh Tekhnologii, Mekhaniki i Optiki». Сокращенное название: «Sci.Tech. J. Inf. Technol. Mech. Opt.»

Журнал включен в каталог периодических изданий Ulrich's Periodical Directory.

Журнал входит в крупнейшие международные реферативные и научометрические базы Scopus, EBSCO, ProQuest, EastView, ИВИС и другие.

Журнал входит в утвержденный Высшей аттестационной комиссией «Перечень ведущих рецензируемых научных журналов и изданий, выпускаемых в Российской Федерации, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученой степени доктора и кандидата наук».

Периодичность издания — 6 выпусков в год.

**Плата за публикации и редактирование не взимается.**

Редакторы: Ю.В. Михайлова, Л.Н. Точилина, Т.В. Точилина  
Перевод — Н.А. Корнев  
Компьютерная верстка — Е.С. Егорова  
Сайт — К.В. Малькова

Оф. 2136, Университет ИТМО, ул. Ломоносова, д. 9,  
Санкт-Петербург, Российская Федерация, 191002

Телефон (812) 480 02 75  
<http://ntv.ifmo.ru>  
E-mail: ntvitmo@ifmo.ru

Статьи Журнала доступны по лицензии Creative Commons  
«Attribution-NonCommercial» 4.0 Всемирная.

Подписано к печати 01.10.2024 Тираж 350 экз. Заказ № 101 (153)

Издание Университета ИТМО

Отпечатано в ООО «Университетские телекоммуникации»

Адрес: 199034, Санкт-Петербург, Биржевая линия, д. 16

© Университет ИТМО

**Editor-in-Chief — Vladimir O. Nikiforov**, D.Sc., Professor

#### EDITORIAL BOARD

**Sergey V. Bezzateev** — D.Sc., Associate Professor (Russia)  
**Andrey V. Belikov** — D.Sc., Professor (Russia)  
**Igor A. Bessmertny** — D.Sc., Professor (Russia)  
**Alexey A. Bobtsov** — D.Sc., Professor (Russia)  
**Alexandr V. Boukhanovsky** — D.Sc. (Russia)  
**Konstantin N. Volkov** — D.Sc. (Great Britain)  
**Konstantin V. Dukelskii** — D.Sc., Associate Professor (Russia)  
**Denis V. Efimov** — PhD (France)  
**Danil A. Zakoldaev** — PhD, Associate Professor (Russia)  
**Ivan V. Iorsh** — D.Sc. (Russia)  
**Nikolai S. Karmanovskiy** (Deputy Chief Editor) — PhD, Associate Professor (Russia)  
**Igor I. Komarov** — PhD, Associate Professor (Russia)  
**Iuri N. Matveev** — D.Sc., Professor (Russia)  
**Nikolay V. Nikonorov** — D.Sc., Professor (Russia)  
**Grigorii S. Polishchuk** — PhD (Russia)  
**Alexey E. Romanov** — D.Sc., Professor (Russia)  
**Irina G. Sidorkina** — D.Sc., Professor (Russia)  
**Oleg A. Stepanov** — D.Sc., Professor (Russia)  
**Tatiana M. Tatarnikova** — D.Sc., Associate Professor (Russia)  
**Andrey V. Timofeev** — Dr. habil. Sc. (Kazakhstan)  
**Mayya V. Uspenskaya** — D.Sc., Professor (Russia)  
**Anton N. Tsyplkin** — D.Sc., Professor (Russia)

**Executive secretary — Irina V. Malkova**

Founder: ITMO University

Publication is registered by the Federal Inspectorate Service for Communication, Information Technologies and Communication Media, certificate PI FS77-67 990 dated December, 6th, 2016.

Languages of the journal: Russian, English

ISSN 2226-1494 (print version), ISSN 2500-0373 (online version)

The English title is "Scientific and Technical Journal of Information Technologies, Mechanics and Optics".

Transliterated title is "Nauchno-Tekhnicheskii Vestnik Informatsionnykh Tekhnologii, Mekhaniki i Optiki".

Abbreviated parallel title: "Sci.Tech. J. Inf. Technol. Mech. Opt."

The journal is catalogued in Ulrich's Periodical Directory.

The journal is included in the largest international abstract and scientometric databases Scopus, EBSCO, ProQuest, East View, EVIS and others.

The journal is included in the "List of leading scientific journals and periodicals under review in the Russian Federation, where the main scientific results of theses for the PhD and doctor of sciences degree must be published" approved by the Higher Attestation Commission.

Publication frequency is 6 times a year.

**Publication and editing are free of charge.**

Editors: Yulia V. Mikhailova, Lyubov N. Tochilina, Tatiana V. Tochilina  
English Language Technical Editor — Nikolay A. Kornev  
Computer layout — Ekaterina S. Egorova  
Website — Ksenia V. Malkova

of. 2136, ITMO University, Lomonosova Street, 9,  
St.Petersburg, 191002, Russia

Phone (812) 480 02 75  
<http://ntv.ifmo.ru/en>  
E-mail: ntvitmo@ifmo.ru



## ОБЗОРНЫЕ СТАТЬИ

## REVIEW PAPERS

doi: 10.17586/2226-1494-2024-24-5-669-686  
УДК 004.5, 004.93

### Автоматический сурдоперевод: обзор нейросетевых методов распознавания и синтеза звучащей и жестовой речи

Денис Викторович Иванько<sup>1</sup>✉, Дмитрий Александрович Рюмин<sup>2</sup>

<sup>1,2</sup> Санкт-Петербургский Федеральный исследовательский центр Российской академии наук, Санкт-Петербург, 199178, Российская Федерация

<sup>1</sup> ivanko.d@iias.spb.su✉, <https://orcid.org/0000-0003-0412-7765>

<sup>2</sup> ryumin.d@iias.spb.su, <https://orcid.org/0000-0002-7935-0569>

#### Аннотация

**Введение.** Представлен обзор современных методов и технологий автоматического машинного сурдоперевода, включающих распознавание и синтез как звучащей, так и жестовой речи. Рассмотренные методы предназначены для обеспечения эффективной коммуникации между глухими, слабослышащими и слышащими людьми. Предложенные решения могут найти применение в современных интерфейсах человека-машинного взаимодействия. **Методы.** Рассмотрены ключевые аспекты новых технологий, включая методы распознавания и синтеза жестовой речи и аудиовизуальной речи, существующие наборы данных для обучения нейросетевых моделей, а также современные системы автоматического машинного сурдоперевода. Представлены актуальные нейросетевые подходы, включающие использование методов глубокого обучения, таких как сверточные и рекуррентные нейросети, а также трансформеры. Приведен анализ существующих наборов данных для обучения систем распознавания и синтеза речи, проблем и ограничений существующих систем машинного сурдоперевода. **Основные результаты.** Выявлены основные недостатки и конкретные проблемы текущих технологий автоматического машинного сурдоперевода. Определены перспективные пути их решения. Особое внимание уделено возможности применения автоматических систем машинного сурдоперевода в реальных условиях. **Обсуждение.** Показана необходимость дальнейших исследований в области сбора и разметки данных. Доказана целесообразность разработки новых методов и нейросетевых моделей, а также создания инновационных технологий для обработки аудио- и видеоданных с целью улучшения качества и эффективности существующих систем автоматического машинного сурдоперевода.

#### Ключевые слова

автоматическое распознавание речи, синтез речи, распознавание жестов, синтез жестов, автоматический сурдоперевод, машинное обучение

#### Благодарности

Раздел «Предмет исследования» выполнен при поддержке бюджетной темы (№ FFZF-2022-0005), остальные исследования выполнены при финансовой поддержке Российского научного фонда (проект № 23-71-01056).

**Ссылка для цитирования:** Иванько Д.В., Рюмин Д.А. Автоматический сурдоперевод: обзор нейросетевых методов распознавания и синтеза звучащей и жестовой речи // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 669–686. doi: 10.17586/2226-1494-2024-24-5-669-686

### Automatic sign language translation: a review of neural network methods for recognition and synthesis of spoken and signed language

Denis V. Ivanko<sup>1</sup>✉, Dmitry A. Ryumin<sup>2</sup>

<sup>1,2</sup> St. Petersburg Federal Research Center of the Russian Academy of Sciences, Saint Petersburg (SPC RAS), 199178, Russian Federation

<sup>1</sup> ivanko.d@iias.spb.su✉, <https://orcid.org/0000-0003-0412-7765>

<sup>2</sup> ryumin.d@iias.spb.su, <https://orcid.org/0000-0002-7935-0569>

© Иванько Д.В., Рюмин Д.А., 2024

**Abstract**

A review of modern methods and technologies for automatic machine translation for the deaf and hard of hearing is presented, including recognition and synthesis of both spoken and sign languages. These methods aim to facilitate effective communication between deaf/hard-of-hearing and hearing individuals. The proposed solutions have potential applications in contemporary human-machine interaction interfaces. Key aspects of new technologies are examined, including methods for sign language recognition and synthesis, audiovisual speech recognition and synthesis, existing corpora for training neural network models, and current systems for automatic machine translation. Current neural network approaches are presented, including the use of deep learning methods such as convolutional and recurrent neural networks as well as transformers. An analysis of existing corpora for training recognition and synthesis systems is provided, along with an evaluation of the challenges and limitations of existing machine translation systems. The main shortcomings and specific problems of current automatic machine translation technologies are identified, and promising solutions are proposed. Special attention is given to the applicability of automatic machine translation systems in real-world scenarios. The need for further research in data collection and annotation, development of new methods and neural network models, and creation of innovative technologies for processing audio and video data to enhance the quality and efficiency of the existing automatic machine translation systems is highlighted.

**Keywords**

automatic speech recognition, speech synthesis, gesture recognition, gesture synthesis, automatic sign language translation, machine learning

**Acknowledgements**

The section “Research Subject” was carried out with the support of the budget topic (No. FFZF-2022-0005), the remaining studies were carried out with the financial support of the Russian Science Foundation (project No. 23-71-01056).

**For citation:** Ivanko D.V., Ryumin D.A. Automatic sign language translation: a review of neural network methods for recognition and synthesis of spoken and signed language. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 669–686 (in Russian). doi: 10.17586/2226-1494-2024-24-5-669-686

**Введение**

Автоматический машинный перевод речи с одного языка на другой играет ключевую роль в устраниении языковых барьеров и обеспечении коммуникации между людьми, говорящими на разных языках. Это имеет огромное значение в международных деловых отношениях, туризме, образовании, научных исследованиях, и многих других сферах. За последние годы нейросети стали популярным инструментом для автоматического машинного перевода звучащей речи благодаря своей способности обучаться на больших объемах данных и выявлять сложные шаблоны и зависимости между языками [1].

В то же время автоматический машинный сурдоперевод — технология, которая способна значительно облегчить жизнь людям с нарушением слуха, обеспечивая им доступ к устной коммуникации. Однако, в отличие от звучащей речи, основным каналом передачи жестовой речи является визуальный. Потому для реализации надежной системы автоматического машинного сурдоперевода требуется многомодальный подход, учитывающий визуальную и акустическую составляющие. Несмотря на большой научный прогресс, достигнутый в области автоматического машинного перевода звучащей речи, а также в области компьютерного зрения, надежная технология автоматического машинного сурдоперевода до сих пор не реализована по некоторым причинам:

- сложность восприятия жестов: существует большое разнообразие жестов, которые используются в различных языках жестовой речи, и их интерпретация может быть сложной для автоматических систем;
- контекстуальная зависимость: понимание различных жестикуляций требует учета контекста и ситуации, что может быть сложно для методов обработки

жестов на основе машинного обучения, особенно в разнообразных сценариях коммуникации;

- технические ограничения: точное распознавание и интерпретация жестов требует высокоточных сенсорных устройств и сложных методов машинного обучения для обработки данных, что может быть технически сложно и затратно;
- жестовые наборы данных (корпуса): на сегодняшний день не существует полностью репрезентативных корпусов жестовой речи пригодных для обучения современных моделей на основе глубоких нейросетей.

В целом автоматический машинный сурдоперевод представляет собой перспективную технологию, но требует дальнейших исследований и разработок, чтобы достичь полной реализации и обеспечить эффективное использование в повседневной жизни.

Учитывая, что область автоматического сурдоперевода находится на пересечении нескольких областей знаний, таких как распознавание речи, компьютерное зрение, машинное обучение и т. д., в настоящей работе рассмотрены достижения современной науки по основным аспектам, комплексирование которых приведет к созданию надежной системы автоматического машинного сурдоперевода. Например, приведен анализ методов распознавания и синтеза жестовой речи, методов распознавания и синтеза аудиовизуальной речи, анализ существующих жестовых корпусов для обучения нейросетевых моделей и анализ существующих систем автоматического машинного сурдоперевода.

**Предмет исследования**

Существующие методы автоматического распознавания и синтеза звучащей и жестовой речи уже применяются в некоторых практических приложениях.

Однако их качество и надежность при работе в реальных условиях остаются недостаточно высокими, что представляет серьезную научно-техническую проблему. В то же время систем, позволяющих осуществлять автоматический двухсторонний машинный сурдоперевод на основе распознавания и синтеза аудиовизуальной и жестовой речи практически не существует [2]. Для решения этих проблем необходимо продолжить разработку новых методов улучшения качества распознавания, включая увеличение объемов и качества тренировочных данных, а также использование более совершенных моделей машинного обучения и сенсорных технологий.

В настоящее время отсутствует единый подход к разработке интеллектуальных систем автоматического двустороннего машинного сурдоперевода как в России, так и за рубежом. Существует множество нерешенных, но важных проблем и задач, которые требуют внимания ученых со всего мира. Среди ключевых проблем в этой области можно выделить следующие: сбор, анализ и аннотирование представительных аудиовизуальных речевых и жестовых корпусов, записанных в естественных условиях. Отсутствие общепринятых нейросетевых архитектур и моделей распознавания и синтеза жестовой и звучащей речи. В целом эти проблемы ставят перед исследователями серьезные вызовы, и их решение требует совместных усилий и междисциплинарного подхода со стороны ученых и специалистов по обработке цифровых сигналов, машинному обучению и компьютерному зрению.

Автоматический машинный перевод с жестовых языков сопряжен со значительными трудностями по сравнению с обработкой звучащих языков. Это обусловлено рядом факторов, связанных с задачами компьютерного зрения и машинного обучения:

- окклюзии: жестовая речь часто сопровождается движениями различных частей тела, таких как руки, голова и туловище. Это может привести к перекрытию (окклюзиям) между различными частями тела, что усложняет точное распознавание и интерпретацию жестов и жестикуляций;
- различия в фоновом освещении: изменения в освещении могут привести к изменению теней и контраста, что делает сложным обнаружение и выделение жестов в различных условиях освещения;
- необходимость больших вычислительных ресурсов: обработка и анализ видеоданных, особенно при высоком разрешении, требует значительных вычислительных ресурсов для обеспечения высокой точности и скорости обработки;
- недостаточный объем корпусов: для эффективного обучения моделей машинного обучения необходимы большие и разнообразные корпуса, содержащие различные жесты в разных условиях. Недостаточный объем таких корпусов может привести к малой обученности нейросетевых моделей;
- нелинейная структура высказывания: в отличие от звучащих языков, жестовые языки обладают визуальной природой и обычно имеют нелинейную структуру высказывания (несколько жестов могут выполняться одновременно, имея различные пространственные координаты и контексты);

- динамическая природа жестов: жесты могут изменяться в зависимости от скорости и плавности движений. Некоторые жесты могут быть выполнены быстрее или медленнее в зависимости от ситуации, что требует от автоматической системы гибкости в интерпретации;
- разнообразие жестовых языков и диалектов: существует множество жестовых языков и диалектов, каждый из которых имеет свои уникальные жесты и правила, что усложняет создание универсальной модели перевода;
- пользовательский интерфейс и эргономика: разработка интуитивно понятных и удобных интерфейсов для пользователей с нарушением слуха, которые способны обеспечивать эффективное взаимодействие с автоматической системой перевода;
- лингвистические и культурные различия: жестовые языки часто содержат культурные и контекстуальные особенности, которые могут быть сложны для автоматического машинного перевода без учета соответствующих культурных контекстов;
- точность и достоверность перевода: обеспечение высокой точности машинного перевода критически важно, так как ошибки могут приводить к серьезным ошибкам. Например, в медицинских контекстах неправильный перевод может привести к неверной интерпретации симптомов или предписаний, что может серьезно повлиять на здоровье пациента.

Многочисленные междисциплинарные исследования подчеркивают важность визуальной информации в понимании звучащей речи [3]. Например, наблюдение за лицом собеседника значительно облегчает восприятие речи. Сигналы из визуальных и слуховых каналов взаимодополняются, помогают правильно воспринимать речь в сложных условиях, таких как динамические акустические шумы. Особенно это важно для людей со слабым слухом, которые часто опираются на визуальные данные, такие как движения губ и мимика лица. В результате во многих странах мира проводятся исследования и разработки автоматических систем аудиовизуального распознавания речи для основных мировых языков [4–6].

Помимо вышеупомянутых факторов, решение указанной научной проблемы осложняется ограниченностью русскоязычных корпусов по размеру и доступным данным. В отличие от аналогичных корпусов на других языках, таких как английский, немецкий или китайский, русскоязычных корпусов жестовой и аудиовизуальной речи значительно меньше. Это подчеркивает необходимость использования широкого спектра дополнительных подходов, методов и алгоритмов для решения поставленных задач в условиях ограниченного объема доступных данных. В частности, необходимо исследование новых подходов к аугментации данных и адаптации иноязычных ресурсов для русскоязычного контекста.

В последние десятилетия значительное внимание уделяется разработке и совершенствованию технологий обработки речи, включая распознавание аудиовизуальной и жестовой речи, а также синтезу акустической и жестовой речи. Именно поэтому в настоящей работе

рассматриваются основные методы и достижения в области распознавания и синтеза аудиовизуальной и жестовой речи.

Распознавание аудиовизуальной речи — процесс автоматического определения речевых звуков по видеозаписям говорящего. Он объединяет информацию из акустического и визуального потоков данных для более точного распознавания речи.

Синтез акустической речи — процесс генерации звучащей речи из текстовых данных. Современные методы синтеза акустической речи, используют глубокие нейросети для моделирования акустических признаков речи и создания естественно звучащей речи с высоким качеством, интонацией и эмоциями.

Распознавание жестовой речи — процесс автоматического определения жестов и движений рук и тела, используемых для передачи визуальной информации. Методы распознавания жестовой речи включают в себя как классические подходы [7], основанные на анализе признаков и классификации жестов, так и современные методы, такие как глубокие нейросети, использующиеся для извлечения и интерпретации динамических жестов.

Синтез жестовой речи — процесс генерации анимированных движений рук, тела и мимики лица, соответствующих передаваемой информации. Методы синтеза жестовой речи включают в себя использование моделей движения и анимации, основанных на данных о реальных жестах и выражениях лица, а также генеративных нейросетей, создающих реалистичные и естественные движения аватаров.

Отметим конкретные проблемы и недостатки текущих технологий автоматического машинного сурдоперевода:

- точность распознавания: одной из основных проблем современных систем автоматического машинного сурдоперевода является недостаточная точность распознавания жестов. Это вызвано множеством факторов, таких как разнообразие жестов, различные диалекты жестовой речи и ограниченные объемы обучающих данных;
- синхронизация жестов и аудиовизуальной речи: еще одной важной проблемой является синхронизация. Текущие технологии часто не обеспечивают необходимую синхронизацию распознавания звучащей и жестовой речи, что приводит к искажению смысла передаваемой информации;
- интеграция различных моделей в единую систему сурдоперевода: современные системы автоматического машинного сурдоперевода часто сталкиваются с трудностями интеграции различных компонентов, таких как распознавание жестов, синтез речи и обработка аудиовизуальных данных.

Распознавание аудиовизуальной и жестовой речи, а также синтез акустической и жестовой речи, представляют собой важные направления исследований в области обработки речи. Современные методы и технологии в этой области обладают потенциалом для создания более эффективных и интуитивно понятных систем коммуникации, обучения и развлечений, содействуя развитию более доступной среды человека-машинного взаимодействия для всех пользователей.

## Автоматическое распознавание жестовой речи

В последнее десятилетие ученые по всему миру активно проводят научно-технические исследования, особенно в областях компьютерного зрения, машинного обучения и обработки сигналов, и разрабатывают новые технологии автоматического распознавания жестовой речи для глухих людей. Основные методы распознавания жестовой речи приведены в табл. 1.

В работе [8] представлен метод оценки положения и классификации формы руки с применением многоуровневого метода композиции рандомизированных лесов решений. В [9] предложен метод отслеживания положения руки в реальном времени с использованием данных от датчиков глубины и 3D-модели руки, состоящей из 21 сегмента, а также применен метод леса случайных решений для классификации пикселей и совместной оценки местоположения. В [10] представлена генеративная нейросетевая модель и метод, основанный на данных о глубине, для отслеживания движений руки с использованием функции расстояния для моделирования ее геометрии и быстрой оптимизации при высокой частоте кадров. Предложенный подход позволял отслеживать взаимодействие между двумя руками или другими объектами.

Работа [11] посвящена разработке системы компьютерного зрения в реальном времени, предназначеннной для помощи пациентам с нарушениями слуха в больничных условиях. Система задает пациентам ряд вопросов для определения цели их визита, принимая ответы через язык жестов. В работе предложено использовать временные накопительные признаки для распознавания изолированных жестов. Этот метод включает элементы, специфичные для жестового языка, для захвата его лингвистических характеристик, что позволило создать эффективную и быструю систему распознавания. В [12] представлен метод перевода жестового языка в письменный текст с использованием глубоких нейросетей. Сделана попытка улучшить системы перевода, включив в процесс токенизацию для более точного отображения лингвистической структуры жестового языка.

В [13] описан метод перевода жестовой речи в письменный текст с использованием глубоких нейросетей. Выполнен анализ лингвистической структуры жестовых языков с помощью нейросетевого метода, с целью оценить потенциал нейросетей для улучшения систем перевода. В работе [14] исследовано обучение для систем распознавания жестовой речи с использованием многопоточной модели CNN-LSTM-HMM с целью выявления последовательного параллелизма в видео. Осуществлено обучение модели на слабо размеченных данных и продемонстрирован потенциал машинного обучения для улучшения систем перевода.

В [15] изучена проблема мультиартикуляции и предложена многоканальная архитектура трансформера. Эта архитектура позволяет моделировать меж- и внутриконтекстные отношения между различными каналами, сохраняя при этом информацию, относящуюся к конкретному каналу. Представленная в работе архитектура объединила задачи распознавания и перевода в единую

Таблица 1. Основные методы распознавания жестовой речи

Table 1. Sign Language Recognition Methods

Ссылка	Метод	Описание
[8]	Многоуровневый метод рандомизированных лесов решений	Метод оценки положения и классификации формы руки с использованием композиции рандомизированных лесов решений
[9]	Датчики глубины, трехмерная (3D) модель руки	Метод отслеживания положения руки в реальном времени с использованием данных от датчиков глубины и 3D-модели руки на основе леса решений
[10]	Данные о глубине, функция расстояния, быстрая оптимизация, геометрия руки	Генеративная нейросетевая модель и метод отслеживания движений руки с использованием данных о глубине и функции расстояния
[11]	Временные накопительные признаки	Использование временных накопительных признаков для распознавания изолированных жестов рук
[12]	Глубокие нейросети, токенизация	Метод перевода жестового языка в письменный текст с использованием глубоких нейросетей
[13]	Нейросетевой метод анализа лингвистической структуры, перевод	
[14]	Многопоточная нейросетевая модель Convolutional Neural Network — Long Short-Term Memory — Hidden Markov Model (CNN-LSTM-HMM)	Обучение систем распознавания жестовой речи с использованием многопоточной модели CNN-LSTM-HMM
[15]	Трансформер, объединение задач распознавания и перевода	Нейросетевая архитектура на основе трансформера для объединения задач распознавания и перевода в единую модель
[16]	3DCNN, LSTM	Метод комбинирования 3DCNN и LSTM для мультимодального распознавания жестов
[17]	3DCNN	Метод улучшения динамического распознавания жестов рук с использованием 3DCNN
[18]	Глубокие CNN, RGB-D	Метод обучения многомерным функциям для распознавания жестов RGB-D с использованием глубоких CNN
[19]	Скоростные и мультимодальные нейросети	Метод распознавания жестов с использованием скоростных и мультимодальных нейросетей с временным расширением
[20]	Ансамбль CNN	Метод распознавания жестов с использованием ансамбля глубоких CNN
[21]	Ансамбль CNN, Oriented FAST and Rotated BRIEF (ORB) дескриптор, фильтр Габора	Метод извлечения жестовых признаков на основе CNN, ORB-дескриптора и фильтров Габора

модель. Это значительно повысило производительность по сравнению с обычными методами, где распознавание и перевод выполняются как отдельные процессы. Также в работе [15] рассмотрена совместная задача по переводу, в которой использована модель чистого текста. Цель исследования заключалась в улучшении перевода жестового языка в письменный текст с помощью данной методологии.

В [16] представлен метод, сочетающий 3DCNN и сверточный LSTM для мультимодального распознавания жестов, демонстрирующий эффективность такой комбинации. В работе [17] предложен метод, который улучшает динамическое распознавание жестов рук с использованием 3DCNN путем внедрения знаний из нескольких модальностей в отдельные сети. В [18] использован MultiD-CNN, метод обучения многомерным функциям для распознавания жестов RGB-D с использованием глубоких CNN. В [19] рассмотрен метод распознавания жестов с использованием многоскоростных и мультимодальных нейросетей с временным расширением, в которых применен алгоритм поиска для определения оптимальной комбинации архитектуры

нейросети, временной информации о разрешении и модальности.

В работе [20] исследованы ансамблевые методы для изолированных жестов, а также метод с использованием ансамбля нескольких глубоких CNN. В свою очередь, в [21] предложено выполнять объединение сверточных нейросетей с ORB-дескриптором и фильтром Габора для более эффективного распознавания языка жестов по видео.

Наряду с вышеописанными методами, в [22] представлен всесторонний обзор методов распознавания и синтеза жестов рук, включая методы на основе компьютерного зрения, машинного обучения и носимых устройств. Следует также отметить ученых из Университета Карнеги-Меллона (США), которые одними из первых разработали решение с открытым исходным кодом для определения множества ориентиров скелета и лица (модель человеческого скелета) на отдельных изображениях в режиме реального времени. Подробное описание библиотеки с открытым исходным кодом OpenPose представлено в [23]. В то же время Google активно разрабатывает кроссплатформенную

среду с открытым исходным кодом MediaPipe [24], которая включает новые методы, основанные на глубоком обучении, для определения трехмерных ориентиров лица, рук и тела человека.

### Автоматический синтез жестовой речи

Первоначально автоматический синтез жестовой речи в виде 3D-аватаров был предложен в качестве инструмента для облегчения общения и взаимодействия людей с ограниченными возможностями — глухими или слабослышащими людьми [25]. Для таких людей жестовая речь является естественным средством общения, и автоматический синтез жестовых аватаров позволяет им взаимодействовать с другими людьми и компьютерными системами наравне со слышащими людьми.

В современном мире 3D-аватары могут использоваться в различных сферах деятельности. Например, в развлекательной индустрии аватары применяются для создания интерактивных виртуальных персонажей в видеоиграх, фильмах или виртуальной реальности. Это позволяет пользователям взаимодействовать с виртуальными мирами и персонажами более естественным образом, что улучшает их игровой опыт и вовлеченность.

Кроме того, методы автоматического синтеза жестовой речи в виде 3D-аватаров могут быть полезны в медицинских приложениях. Например, в реабилитации пациентов с нарушениями речи или движения такие методы помогут восстановлению навыков общения и моторики. Также данные методы могут быть применены для обучения медицинского персонала в области коммуникации с людьми с ограниченными возможностями.

Одним из ключевых преимуществ автоматического синтеза жестовой речи в виде 3D-аватаров является его возможность улучшить виртуальное общение и телекоммуникации. В наше время, когда все больше людей

переходят на удаленную работу и обучение, эта технология может стать важным средством для создания более естественного и привлекательного виртуального взаимодействия.

Нейросетевые методы синтеза жестовых аватаров используют глубокие нейросети для создания анимированных персонажей или аватаров, которые могут эмитировать жестовую речь и другие движения. Основные нейросетевые методы синтеза жестовой речи и 3D-аватаров, а также их характеристики приведены в табл. 2.

YOLO [26]. Методы глубокого машинного обучения версии YOLO, применяются для распознавания и моделирования последовательностей жестов рук в реальном времени на изображениях или видео. Основное преимущество YOLO заключается в его способности к выполнению локализации и классификации жестов за один проход, что обеспечивает высокую скорость работы и эффективность. В отличие от других методов, которые разделяют процессы локализации и классификации на несколько этапов, YOLO анализирует изображение или видеопоток в целом, одновременно определяя расположение рук и класс жеста.

cGANs [27]. Методы используют генеративные состязательные нейросети для синтеза жестовых аватаров на основе входных данных разной модальности. Они позволяют генерировать реалистичные изображения жестовых аватаров, учитывая входные параметры.

VAEs [28]. Методы применяются для сжатия и генерации жестовых аватаров на основе обучающих данных. Эти нейросетевые модели обучаются на больших жестовых наборах данных и могут генерировать 3D-аватары с учетом обученной нейросетевой модели. Они позволяют создавать реалистичные 3D-аватары, сохраняя при этом их выразительность и уникальные характеристики, что полезно в различных приложениях, таких как обучение жестовой речи, виртуальная реальность и анимация персонажей.

*Таблица 2. Основные нейросетевые методы синтеза жестовой речи и 3D-аватаров*  
*Table 2. Neural Sign Language Synthesis and 3D Avatar Methods*

Ссылка	Метод	Описание
[26]	You Only Look Once (YOLO)	Распознавание жестов рук в реальном времени на основе глубокого обучения с использованием версий YOLO обеспечивает высокую точность и скорость классификации, что подходит для интерактивных приложений
[27]	conditional Generative Adversarial Networks (cGANs)	Методы генеративных состязательных нейросетей для синтеза жестовых аватаров
[28]	Variational Autoencoders (VAEs)	Методы на основе вариационных автокодировщиков для генерации жестовых аватаров
[29]	LSTMs	Рекуррентные нейросети с длинной кратковременной памятью для анализа последовательностей жестов
[30]	Convolutional Neural Networks (CNNs)	Методы на основе сверточных нейросетей для эффективного извлечения пространственных признаков из изображений жестов
[31]	Graph Convolutional Networks (GCNs)	Графовые нейросети для анализа структуры и взаимосвязи между жестами в пространстве
[32]	Механизмы внимания	Механизмы внимания позволяют модели сосредоточиться на определенных частях жеста
[33]	Трансформеры	Модели на основе трансформера могут эффективно моделировать долгосрочные зависимости

LSTMs [29]. Методы реализуются для моделирования долгосрочных зависимостей в жестовых последовательностях, позволяя эффективно улавливать контекст и выражения различных движений. Благодаря этому LSTMs способны генерировать аватары, которые не только соответствуют входным жестам, но и сохраняют связанные с ними эмоциональные и динамические особенности.

CNNs [30]. Сверточные нейросети эффективно извлекают пространственные признаки из изображений жестов, что делает их полезными для синтеза жестовых аватаров. Они способны адаптироваться к различным аспектам жестов, включая формы рук и их позы, а также выражения лица и жесты других частей тела. Эти особенности делают их подходящими для создания аватаров, которые не только точно отражают входные жесты, но и захватывают их выразительность и эмоциональную окраску.

GCNs [31]. Графовые нейросети способны анализировать сложные взаимосвязи между жестами в 3D-пространстве. Они оперируют на основе графовых структур, где узлы представляют собой жесты, а ребра — их взаимодействия и связи. Это позволяет методам GCNs эффективно учитывать контекст и зависимости между жестами, что особенно важно для синтеза жестовых аватаров с реалистичным поведением и выражением. В процессе машинного обучения GCNs учитывают геометрическую структуру пространства жестов, а также динамику изменения этих жестов с течением времени. Благодаря этому они способны обнаруживать сложные шаблоны и взаимосвязи, которые могут быть упущены другими методами, и использовать эту информацию для создания более реалистичных и выразительных жестовых аватаров.

Механизмы внимание [32]. В контексте синтеза жестовых аватаров данные методы играют важную роль, позволяя нейросетевым моделям сосредоточиться на наиболее значимых или информативных частях жеста. Этот принцип достигается за счет выделения ключевых аспектов жеста и удаления им особого внимания в процессе генерации аватара. Механизмы внимания могут включать в себя идентификацию ключевых точек в пространстве, определение эмоционального содержания жеста или выделение динамических аспектов движения. Путем акцентирования на этих важных деталях модели способны создавать более реалистичные и выразительные жестовые аватары, которые точнее передают эмоциональное и содержательное содержание жестов.

Трансформеры [33]. Нейросетевые модели на основе трансформеров способны эффективно моделировать долгосрочные зависимости в последовательностях жестов, что полезно для синтеза жестовых аватаров, учитывая контекст и динамику движения.

Таким образом, вышеупомянутые исследования направлены на решение задач эффективного комплексного интеллектуального анализа движений тела человека для автоматического синтеза жестового языка и аватаров. Отметим, что полностью абстрагироваться от цифровой сцены (видеоинформации) и анализировать только динамически меняющееся состояние (поведение) человека (в том числе и жесты) пока достаточно

сложно. В настоящее время не существует полностью автоматических нейросетевых моделей и методов для машинных систем распознавания жестовой речи и 3D-аватаров для синтеза элементов жестового языка.

### **Автоматическое распознавание речи по аудиовизуальным данным**

Традиционно системы аудиовизуального распознавания речи состоят из двух этапов обработки: извлечение признаков из аудио- и визуальной информации с последующим распознаванием речи [34, 35]. При традиционных методах информативные признаки обычно извлекаются из интересующей области рта и из аудиосигнала, а затем объединяются [36, 37].

В последние годы, с развитием технологий глубокого машинного обучения и компьютерного зрения, было представлено множество нейросетевых методов, которые заменили этап извлечения признаков. Первый нейросетевой классификатор изображений сверточной нейросети для распознавания визуальных признаков обучен в работе [38]. В [39] нейросетевые признаки использованы для распознавания слов, чтобы в полной мере применить глубокие сверточные слои. В работе [40] предложено использовать трехмерные сверточные фильтры для обработки пространственно-временной информации о губах, а в [41] применен механизм внимания к интересующей области рта.

В работах [42–44] рассмотрены интегральные (сквозное тестирование) нейросетевые архитектуры для систем автоматического распознавания речи, которые привлекли большое внимание исследователей по распознаванию аудиовизуальной речи. Основным преимуществом современного интегрального подхода является возможность как выделения признаков, так и этапов классификации в границах одной нейросети. Эти методы можно разделить на две группы. В первой группе одни и те же слои используются для извлечения признаков и моделирования временной динамики. Во второй — сверточные слои применены для извлечения признаков, за которыми следуют LSTM или Gated Recurrent Unit (GRU) для моделирования результатов распознавания.

В последнее время интегральные методы успешно используются для многих задач распознавания, синтеза речи и задач компьютерного зрения. Можно отметить работы [45, 46], в которых механизм внимания применялся как к интересующим областям рта, так и к мел-частотным кепстральным коэффициентам, а модель обучалась интегрально. Затем полно связанные слои, за которыми следует LSTM, используются для извлечения признаков из изображений и спектограмм и выполнения классификации.

Первая интегральная модель, которая выполняла аудиовизуальное распознавание слов на большом наборе данных, описана в работе [47], где предложена двухполярная модель для извлечения признаков. Каждый поток состоял из нейросети ResNet [48], который извлекал признаки из необработанных входных данных, за которыми следует двухуровневый двунаправленный Bidirectional GRU (BiGRU), который моделирует време-

менную динамику в каждом потоке. Этот метод позволяет нейросетевой модели эффективно обрабатывать как аудио-, так и видеоданные и извлекать значимые признаки для распознавания слов. Чтобы построить интегральную нейросеть в [49] использована рекуррентная нейросеть с длинной кратковременной памятью для извлечения признаков из необработанных данных. Обычно существующие методы обрабатывают интересующую область рта целиком, однако в работе [50] предложено использовать отдельные части (области) губ. Исследователи провели сравнительный анализ нейросетей для аудиовизуального распознавания речи, начиная с использования кросс-энтропийной функции потерь и затем переходя к коннекционистской временной классификации.

Первоначально архитектура трансформера была предложена в машинном переводе [51], после чего было проведено множество исследований по ее применению не только в акустическом, но и в аудиовизуальном распознавании речи. Она способна вычислять глобальный контекст для всех входных данных, что приводит к повышению производительности и более стабильному машинному обучению [52]. В работе [53] трансформер был объединен с рекуррентной нейросетью с длинной кратковременной памятью. Таким образом, сочетание современных методов глубокого машинного обучения и крупномасштабных аудиовизуальных корпусов позволяет достигать значительных результатов в точности распознавания.

Существующие методы распознавания аудиовизуальной речи кратко систематизированы в табл. 3.

В последние годы развитие технологий глубокого машинного обучения существенно изменило подходы к аудиовизуальному распознаванию речи. Отказ от традиционных методов извлечения признаков в пользу нейросетевых подходов привел к созданию эффективных интегральных архитектур, объединяющих этапы извлечения признаков и классификации в одной

модели. Эти архитектуры позволяют моделировать как пространственную, так и временную динамику речевых данных, что значительно улучшает точность распознавания речи. В основе глубоких сверточных и рекуррентных нейросетей, а также моделей на основе трансформера, лежат эффективные методы, успешно применяемые к аудио- и визуальным данным. Это позволяет достигать высокой точности в распознавании аудиовизуальной речи даже в сложных условиях. Такой подход обладает значительным потенциалом и является активным направлением исследований в области распознавания аудиовизуальной речи.

### Автоматический синтез акустической речи

Синтез речи играет ключевую роль в современном мире, применяясь в различных областях, от помощи людям с ограниченными возможностями до улучшения пользовательских интерфейсов в мобильных устройствах и автомобилях [54]. Например, для людей со слабым зрением синтез речи становится важным инструментом, преобразующим текстовые данные в аудиоформат, что делает информацию более доступной для восприятия. Это особенно актуально для чтения электронных документов, интернет-страниц и других текстовых материалов.

Кроме того, синтез речи улучшает пользовательские интерфейсы в различных устройствах и интеллектуальных приложениях. Например, в мобильных устройствах и умных домашних системах синтез речи используется для озвучивания текстовых уведомлений, команд голосового управления и других элементов интерфейса, упрощая взаимодействие пользователя с устройством. Это особенно важно для людей с ограниченными возможностями или пожилых, которым сложно использовать клавиатуру или сенсорный экран.

Актуальным направлением исследований в области синтеза речи является разработка голосовых ассистен-

*Таблица 3. Систематизация методов распознавания аудиовизуальной речи*  
*Table 3. Systematization of Audio-Visual Speech Recognition Methods*

Ссылка	Метод	Описание
[34, 37]	Извлечение признаков из области рта и аудиосигнала	Традиционные методы аудиовизуального распознавания речи включают извлечение признаков из интересующей области рта, таких как движения губ и языка, а также из аудиосигнала, таких как мел-частотные кепстральные коэффициенты или спектограммы. Затем эти признаки объединяются для создания комплексного представления речи, которое используется в дальнейшем для распознавания речевых слов или команд
[38–41]	2D-3D сверточные нейросетевые признаки	Нейросетевые методы используются для извлечения признаков из изображений и аудиосигналов. Примеры включают сверточные нейросети для изображений и использование 3D сверточных фильтров для обработки информации о губах
[42–50]	Интегральные нейросетевые архитектуры для распознавания речи	Методы на основе интегральных нейросетевых архитектур объединяют этапы извлечения признаков и классификации в рамках одной нейросети. Это позволяет более эффективно моделировать временную динамику речи
[51–53]	Модели с использованием трансформера	Модель трансформера, исходно разработанная для машинного перевода, успешно применяется в распознавании аудиовизуальной речи. Это позволяет моделировать глобальный контекст для всех входных данных, повышая производительность и стабильность машинного обучения

тов [55], которые позволяют пользователям взаимодействовать с компьютерами и другими устройствами через голосовые команды, что делает процесс взаимодействия более естественным и удобным. Например, голосовые ассистенты используют синтез речи для предоставления ответов на вопросы пользователей и выполнения команд.

Еще одним важным аспектом синтеза речи является его роль в развитии искусственного интеллекта. Технологии синтеза речи используются в различных системах искусственного интеллекта для создания более интеллектуальных и адаптивных интерфейсов. Например, синтез речи может применяться для создания персонализированных рекомендаций и подбора

контента, учитывая предпочтения и интересы пользователей.

Нейросетевые методы синтеза акустической речи представляют собой подходы, использующие глубокие нейросети для генерации речи из текста или других модальностей. Несколько ключевых методов и их особенностей приведены в табл. 4.

Нейросетевые методы синтеза акустической речи продемонстрировали значительный прогресс в последние годы, обеспечивая высокое качество синтеза речи с естественным звучанием. Они широко используются в приложениях распознавания речи, голосовых помощниках, аудиокнигах и других областях, где требуется генерация человекоподобной речи.

*Таблица 4. Нейросетевые методы синтеза звучащей речи*

*Table 4. Neural Network Methods for Speech Synthesis*

Ссылка	Метод синтеза речи	Описание
[56]	WaveNet	Нейросеть, разработанная компанией Google DeepMind, которая использует генеративную модель для синтеза речи. Она создает аудиофайлы, имитирующие человеческую речь, с высоким качеством и естественностью
[57]	Tacotron	Нейросеть, разработанная Google, которая преобразует текст в аудиофайлы с речью. Этот метод использует механизм внимания для преобразования текста в голос
[58]	Deep Voice	Серия нейросетей, разработанных компанией Baidu, которые используются для синтеза речи из текстовых данных. Эти сети обучаются на больших объемах речевых данных для достижения высокого качества генерации речи
[59]	Transformer-TTS	Архитектура нейросетевой модели синтеза речи, основанная на трансформере, которая показывает высокую производительность в задачах генерации речи. Метод использует механизм внимания для преобразования текста в речь
[60]	FastSpeech	Метод синтеза речи, который позволяет синтезировать речь из текста. Метод отличается высокой скоростью работы и качеством сгенерированной речи
[61]	WaveGlow	Нейросеть, разработанная компанией Nvidia, основана на комбинации вариационных автокодировщиков и нормализационных потоков для генерации аудиофайлов. Она работает, пропуская случайный шум через многослойную нейросеть, чтобы создать аудио, имитирующее человеческую речь, с высокой степенью реалистичности и плавности
[62]	MelGAN	Архитектура нейросети, разработанная для синтеза речи, которая использует генеративную модель для генерации аудиосигналов на основе мел-спектрограмм
[63]	Parallel WaveGAN	Архитектура нейросети, основанная на генеративных состязательных сетях GAN и использующая конволюционные нейросети для синтеза аудио. Метод работает, пропуская случайный шум через генератор, который обучается создавать высококачественные аудиофайлы, имитирующие человеческую речь. Дискриминатор оценивает качество синтезированной речи, помогая генератору улучшать свои результаты
[64]	LPCNet	Гибридная архитектура, комбинирующая линейное предсказание коэффициентов (Linear Predictive Coding, LPC) с нейросетями для синтеза речи, объединяя классический метод LPC для моделирования основной формы речи с возможностями нейросетей в выявлении сложных закономерностей данных
[65]	Mel-Spectrogram GAN	Генеративная модель, которая использует мел-спектрограммы для синтеза речи
[66]	HiFi-GAN	Нейросеть, разработанная для синтеза высококачественной речи с помощью генеративно-состязательного метода
[67]	Tacotron 2	Улучшенная версия Tacotron [57], которая использует механизмы внимания для улучшения качества синтеза речи
[68]	Flowtron	Нейросеть, разработанная для синтеза речи с использованием модели потока для генерации аудиосигналов
[69]	WaveGrad	Метод синтеза речи, который использует градиентные методы для генерации аудиосигналов
[70]	ClariNet	Архитектура нейросети, разработанная для синтеза речи на основе глубокого машинного обучения, которая использует спектрограммы

## Корпуса жестовой и аудиовизуальной речи

На сегодняшний день научным сообществом и крупными техническими корпорациями собрано и аннотировано множество аудиовизуальных речевых и жестовых корпусов для решения задач распознавания и синтеза аудиовизуальной и жестовой речи. Такие корпусы играют важную роль в разработке и обучении нейросетевых моделей компьютерного зрения и искусственного интеллекта для распознавания и синтеза звучащей и жестовой речи.

В работе [71] рассмотрены проблемы сбора корпусов жестовой речи для обучения нейросетевых моделей машинного обучения. Данное исследование предоставляет информацию о сложностях сбора высококачественных данных и подчеркивает важность учета конфиденциальности и этических соображений. Междисциплинарное исследование в [72] предоставило всесторонний обзор наборов данных жестовых корпусов, классифицируя их по различным факторам, таким как модальность, язык и применение, а также проводя анализ их пригодности для различных задач. Также в работе [72] выполнен анализ ограничений текущих корпусов и предложены будущие направления для улучшения, что делает их работу важным ресурсом для исследователей и практиков в области распознавания жестовых языков.

Приведем несколько примеров, наиболее часто используемых для задач машинного обучения жестовых корпусов.

**ASL-LEX** [73]. Корпус американского жестового языка (American Sign Language, ASL), содержащий информацию о лексических и семантических свойствах американских жестов.

**RWTH-PHOENIX-Weather 2014T** [74]. Корпус жестовой речи, содержащий видеозаписи жестов, связанных с обсуждением погоды. Используется для исследований по распознаванию жестов и мультимодальной обработке данных.

**MSR Gesture 3D Dataset** [75]. Корпус содержит трехмерные видеозаписи жестов, собранные с помощью камер глубины. Предназначен для разработки методов распознавания жестов с использованием трехмерной информации.

**PHOENIX 2014T** [76]. Крупномасштабный корпус жестовой речи, содержащий видеозаписи жестов и соответствующие текстовые транскрипции на немецком языке.

**ChaLearn Looking at People Dataset** [77]. Корпус содержит различные виды жестов, включая жесты рук, лица и тела, собранные в различных контекстах и для различных задач, таких как распознавание эмоций и действий.

**TheRuSLan** [78]. Корпус мультимедийных материалов по русскому жестовому языку, содержащий лексические единицы, связанные с продуктами питания в супермаркете. Все видеоматериалы представлены в высоком разрешении, а также включают карты глубины, собранные с помощью устройства MS Kinect v2.

**AUTSL** [79]. Крупномасштабный корпус турецкого жестового языка, содержащий данные, записанные с

использованием MS Kinect v2. Корпус включает видеоданные, карту глубины и координаты скелета для каждого жеста.

**HaGRID** [80]. Крупномасштабный корпус от компании Сбер предназначенный для разработки систем распознавания жестов рук с учетом взаимодействия с устройствами. Корпус содержит больше 554 тысяч изображений и аннотации ограничивающих рамок с метками жестов, предназначенные для решения задач обнаружения руки и классификации жестов. Он создан с учетом возможности распознавания не только статических, но и динамических жестов. Для обеспечения разнообразия корпус собран с использованием краудсорсинговых платформ, при участии более 37 тыс. людей в различных сценах с разными условиями естественного освещения.

Эти корпуса представляют собой ценные ресурсы для исследований в области жестовой речи, обеспечивая данные для обучения и тестирования нейросетевых моделей распознавания и интерпретации жестов. Они помогают улучшить точность и эффективность систем распознавания жестов и мультимодальных интерфейсов.

Аудиовизуальные речевые корпуса представляют собой коллекции данных, включающие аудио- и видеозаписи речи, которые используются для разработки и оценки алгоритмов распознавания речи, синтеза речи, распознавания говорящего и других задач обработки речи. Перечислим примеры нескольких наиболее часто используемых в научных работах аудиовизуальных корпусов.

**AVLetters Dataset** [81]. Корпус содержит видеозаписи, на которых показано произношение букв английского алфавита, с соответствующими звуками.

**GRID Corpus** [82]. Корпус включает аудио- и видеозаписи говорящих, произносящих фразы на английском языке, а также текстовые транскрипции.

**Lip Reading in the Wild** [83]. Корпус содержит видеозаписи говорящих, произносящих короткие слова на английском языке.

**MOBIO Dataset** [84]. Данный корпус включает аудио- и видеозаписи говорящих на разных языках, а также биометрические данные лица и голоса. Используется для исследований по мультимодальному биометрическому распознаванию и аутентификации.

**MIRACL-Voice Dataset** [85]. Корпус содержит аудио- и видеозаписи различных речевых команд на нескольких языках, включая английский, французский и немецкий. Используется для разработки и оценки систем распознавания речи и управления голосом.

Перечисленные корпуса позволяют проводить исследования в области аудиовизуальной обработки речи, включая обучение и тестирование нейросетевых моделей, а также их оценку и сравнение с существующими методами, в том числе сравнение с лучшими на данный момент моделями (State-of-the-Art, SOTA).

Однако существующие аудиовизуальные и жестовые корпуса часто ограничены как по количеству данных, так и по разнообразию сценариев и условий. Это ограничение означает, что нейросетевые модели, обученные на этих наборах данных, могут оказаться недостаточно обобщающими для реальных сценариев. Более того,

такие корпуса могут не учитывать разнообразие различных культур, диалектов и аспектов поведения, что осложняет создание универсальных и точных систем распознавания и синтеза звучащей и жестовой речи. Для обучения реальных систем необходимы более разнообразные и объемные корпуса, которые охватывают широкий спектр сценариев и условий, чтобы обеспечить их эффективную работу в различных контекстах и для различных пользователей.

Кроме того, существующие корпуса часто могут быть недостаточно размечены или содержать ограниченное количество аннотированных данных. Также существует проблема доступности данных, поскольку некоторые корпуса могут быть закрытыми или недоступными для широкой общественности, что затрудняет исследования. В целом, для развития более точных, эффективных и универсальных систем распознавания и синтеза звучащей и жестовой речи необходимо больше усилий по созданию и расширению разнообразных и крупномасштабных корпусов, а также по улучшению их разметки и доступности для исследователей.

### **Существующие системы автоматического машинного сурдоперевода**

В последние годы прогресс в области технологий обработки речи привел к разработке и улучшению систем перевода жестового языка для людей с нарушениями слуха или речи. Эти системы играют важную роль в обеспечении коммуникации и доступа к информации для данных групп пользователей. Однако, несмотря на успешные тесты в контролируемых условиях, многие системы сурдоперевода и их отдельные компоненты (распознавание/синтез) сталкиваются с проблемами в реальных условиях применения. Основные причины включают: изменяющиеся условия освещения (в реальных условиях освещение может сильно варьироваться, что негативно влияет на качество видео и, соответственно, на точность распознавания жестов); шум и отвлекающие факторы (в реальных ситуациях окружающий визуальный шум и другие отвлекающие факторы могут мешать точному распознаванию жестов); вариативность жестов (разные люди могут выполнять одни и те же жесты по-разному, что требует от систем высокой гибкости и способности адаптироваться к индивидуальным особенностям); ограниченные обучающие данные (для эффективного обучения систем требуются большие и разнообразные жестовые корпуса, которые часто недоступны или ограничены).

Таким образом, автоматические системы машинного перевода жестовой речи можно разделить на два основных типа: основанные на компьютерном зрении и на сенсорах. Первые используют камеры для захвата жестов и их распознавания с помощью методов машинного обучения, в то время как вторые применяют сенсоры для обнаружения движений рук и пальцев и их преобразования в звучащую речь.

Одним из ключевых аспектов достижения высоких результатов является интеграция различных методов и подходов. Например, использование сверточных нейросетей для обработки визуальных данных в сочета-

нии с разновидностями рекуррентных нейросетей или трансформерами для обработки последовательностей может значительно повысить точность распознавания жестовой речи. Сверточные нейросети эффективно выделяют пространственные признаки жестов, тогда как рекуррентные и трансформеры успешно обрабатывают временные зависимости о различных жестикуляциях и движениях. Кроме того, комбинирование распознавания аудиовизуальных данных с синтезом жестовой речи может существенно улучшить производительность системы в реальных условиях. Например, система может использовать информацию о движениях губ для повышения точности распознавания речи в шумной обстановке. В свою очередь, синтез речи может быть улучшен за счет использования информации о жестах, что обеспечивает более естественное и синхронизированное воспроизведение.

Комбинирование различных методов и подходов в системах автоматического сурдоперевода открывает новые возможности для повышения точности, производительности и естественности перевода. Существующие системы автоматического машинного перевода/сурдоперевода приведены в табл. 5.

Представленные в табл. 5 системы — только небольшая часть существующих технологий перевода жестового языка, и каждая из них имеет свои уникальные особенности и преимущества. Они играют важную роль в обеспечении коммуникации и доступа к информации для людей со слуховыми или речевыми нарушениями. В то же время стоит отметить, что на сегодняшний день не существует надежной системы, комплексирующей распознавание и синтез акустической и жестовой речи.

На основе проведенного анализа можно обозначить следующие основные проблемы в создании систем автоматического машинного сурдоперевода и выделить основные тренды и пути решения для их преодоления.

1) Шум в данных. Одной из основных проблем является наличие шума в данных, который может существенно снизить точность распознавания жестов и синтеза речи. Это вызвано плохим освещением, фоновым шумом или нечеткими изображениями.

Решение: для уменьшения влияния шума необходимо применять методы предобработки данных, такие как фильтрация изображений, улучшение контраста, шумоподавление и другие методы цифровой обработки изображений. Использование данных из различных источников и в разных условиях также способствует обучению более устойчивых к шуму нейросетевых моделей.

2) Вариативность жестов. Жесты могут значительно варьироваться в зависимости от индивидуальных особенностей людей, их стиля жестовой речи и скорости выполнения жестов.

Решение: для повышения точности распознавания необходимо использовать более разнообразные и крупномасштабные корпуса данных, которые учитывают различные стили жестовой речи. Аугментация данных и использование методов регуляризации также способны помочь нейросетевым моделям лучше обобщать новые примеры.

Таблица 5. Системы автоматического машинного сурдоперевода

Table 5. Automatic Machine Sign Language Translation Systems

Система	Основные характеристики	Предназначения/особенности
SignAll [86]	Использует технологии распознавания и синтеза жестовой речи	<ul style="list-style-type: none"> <li>— Предоставляет возможность автоматического сурдоперевода с жестовой речи в текст и обратно;</li> <li>— имеет гибкую архитектуру, позволяющую интегрировать систему в различные среды обучения и коммуникации</li> </ul>
Google Live Transcribe [87]	Распознает аудиосигналы и выводит текстовую транскрипцию	<ul style="list-style-type: none"> <li>— Предназначена в первую очередь для людей с нарушениями слуха, чтобы они могли читать речь в реальном времени;</li> <li>— имеет возможность перевода на несколько языков</li> </ul>
DeepHand [88]	Использует методы машинного обучения для распознавания различных жестикуляций и жестов	<ul style="list-style-type: none"> <li>— Предназначена для автоматического перевода жестовой речи на текст;</li> <li>— имеет возможность адаптации к различным жестовым языкам и стилевым особенностям</li> </ul>
MotionSavvy [89]	Использует камеру для распознавания жестов и перевода их в текст	<ul style="list-style-type: none"> <li>— Ориентирована на общение с людьми, не владеющими жестовым языком, путем автоматического перевода жестов в текст и наоборот;</li> <li>— имеет возможность обучения системы новым жестам и адаптации к индивидуальным особенностям пользователей</li> </ul>
Microsoft Translator [90]	Использует интеллектуальные технологии для автоматического распознавания и синтеза речи	<ul style="list-style-type: none"> <li>— Предназначена для автоматического перевода аудио- и текстовых сообщений;</li> <li>— имеет поддержку множества языков и диалектов</li> </ul>
Motion Gesture Recognition [91]	Использует камеру для распознавания движений и жестов	<ul style="list-style-type: none"> <li>— Позволяет пользователю контролировать устройства и взаимодействовать с компьютером через жестовую речь;</li> <li>— может быть интегрирована в различные платформы, такие как мобильные приложения и игровые консоли</li> </ul>

3) Сложность жестов. Некоторые жесты очень похожи друг на друга, что затрудняет их различие.

Решение: применение более сложных нейросетевых архитектур, таких как трансформеры, способных учитывать контекст и последовательность жестов позволит повысить точность распознавания. Также дополнительное использование многомодальных данных, таких как видео, аудио, карт глубины и т. д., способно улучшить различение подобных жестов.

4) Проблемы с производительностью. Методы, основанные на глубоких нейросетях, часто требуют значительных вычислительных ресурсов для обучения.

Решение: для снижения вычислительных затрат необходимо применять методы компрессии и оптимизации нейросетей, такие как квантизация, дистилляция знаний и использование легковесных архитектур.

### Заключение

Область распознавания и синтеза звучащей и жестовой речи является одной из наиболее активных и перспективных в современной компьютерной науке. Эти технологии находят широкое применение в различных областях, таких как системы управления, обработка естественного языка, компьютерное зрение, медицина, образование и т. д. В последние годы с развитием методов глубокого машинного обучения наблюдается значительный прогресс в области распознавания и синтеза, что позволяет создавать более точные, быстрые и эффективные системы двухстороннего машинного сурдоперевода.

В настоящей работе рассмотрены несколько ключевых аспектов разработки надежной системы автоматического двухстороннего машинного сурдоперевода. Например, методы распознавания и синтеза жестовой и аудиовизуальной речи, а также существующие корпуса и системы сурдоперевода. Проведен тщательный анализ и сделаны выводы о современном состоянии области исследования и наиболее перспективных направлениях по каждому из аспектов.

В последние годы методы глубокого машинного обучения (сверточные, рекуррентные, генеративно-связательные нейросети и трансформеры), стали основными инструментами для решения задач распознавания и синтеза, как звучащей, так и жестовой речи. Эти методы позволяют создавать более точные и эффективные нейросетевые модели, способные работать с различными типами данных и обеспечивать хорошее качество необходимого результата.

Отметим, что существующих аудиовизуальных и жестовых корпусов недостаточно для обучения реальных систем распознавания и синтеза звучащей и жестовой речи. Это связано с тем, что создание качественных корпусов требует больших временных и финансовых затрат, а также экспертных знаний в области сбора и разметки данных. Большинство существующих корпусов содержат ограниченное количество примеров, что затрудняет обучение нейросетевых моделей на реальных данных и приводит к недостаточному качеству их работы в реальных условиях.

Кроме того, существующие системы машинного сурдоперевода имеют определенные ограничения (низ-

кая точность распознавания и медленная скорость синтеза). В результате существующие методы и модели не всегда способны точно обрабатывать разнообразные сценарии и условия использования, такие как различные диалекты, акценты, скорость и интонация речи, а также жесты и мимику лица.

Для преодоления выявленных ограничений и повышения эффективности систем автоматического машинного сурдоперевода в реальных условиях можно выделить следующие перспективные направления для их усовершенствования: улучшение алгоритмов предварительной обработки данных (разработка более эффективных методов для фильтрации шума и улучшения качества видео в условиях плохого освещения; интеграция многоомальных данных (аудио, видео, текст, карты глубины, данные сенсоров и т. д.); обучение на расширенных

корпусах (создание и использование более крупномасштабных и разнообразных жестовых и аудиовизуальных корпусов); оптимизация моделей (применение современных методов машинного обучения и оптимизация моделей для повышения их производительности и устойчивости к изменяющимся условиям).

Для улучшения качества систем распознавания и синтеза речи необходимо продолжить исследования в области сбора и разметки данных, разработки новых методов и моделей глубокого машинного обучения, а также создания инновационных технологий для обработки аудио- и видеоданных. Также важно учитывать особенности различных культур и языков, чтобы обеспечить широкую доступность и использование этих технологий для всех пользователей.

## Литература

- Mehrish A., Majumder N., Bharadwaj R., Mihalcea R., Poria S. A review of deep learning techniques for speech processing // *Information Fusion*. 2023. V. 99. P. 101869. <https://doi.org/10.1016/j.inffus.2023.101869>
- Ryumin D., Ivanko D., Ryumina E. Audio-visual speech and gesture recognition by sensors of mobile devices // *Sensors*. 2023. V. 23. N. 4. P. 2284. <https://doi.org/10.3390/s23042284>
- Axyonov A., Ryumin D., Ivanko D., Kashevnik A., Karpov A. Audio-visual speech recognition in-the-wild: multi-angle vehicle cabin corpus and attention-based method // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2024. P. 8195–8199. <https://doi.org/10.1109/ICASSP48485.2024.10448048>
- Ma P., Haliassos A., Fernandez-Lopez A., Chen H., Petridis S., Pantic M. Auto-AVSR: audio-visual speech recognition with automatic labels // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2023. P. 1–5. <https://doi.org/10.1109/ICASSP49357.2023.10096889>
- Wang X., Mi J., Li B., Zhao Y., Meng J. CATNet: Cross-modal fusion for audio-visual speech recognition // *Pattern Recognition Letters*. 2024. V. 178. P. 216–222. <https://doi.org/10.1016/j.patrec.2024.01.002>
- Ryumin D., Axyonov A., Ryumina E., Ivanko D., Kashevnik A., Karpov A. Audio-visual speech recognition based on regulated transformer and spatio-temporal fusion strategy for driver assistive systems // *Expert Systems with Applications*. 2024. V. 252. Part. A. P. 124159. <https://doi.org/10.1016/j.eswa.2024.124159>
- Ryumin D., Karpov A. Towards automatic recognition of sign language gestures using kinect 2.0 // *Lecture Notes in Computer Science*. 2017. V. 10278. P. 89–101. [https://doi.org/10.1007/978-3-319-58703-5\\_7](https://doi.org/10.1007/978-3-319-58703-5_7)
- Keskin C., Kiraç F., Kara Y.E., Akarun L. Hand pose estimation and hand shape classification using multi-layered randomized decision forests // *Lecture Notes in Computer Science*. 2012. V. 7577. P. 852–863. [https://doi.org/10.1007/978-3-642-33783-3\\_61](https://doi.org/10.1007/978-3-642-33783-3_61)
- Keskin C., Kiraç F., Kara Y.E., Akarun L. Real time hand pose estimation using depth sensors // *Consumer Depth Cameras for Computer Vision: Research Topics and Applications*. 2013. P. 119–137. [https://doi.org/10.1007/978-1-4471-4640-7\\_7](https://doi.org/10.1007/978-1-4471-4640-7_7)
- Taylor J., Tankovich V., Tang D., Keskin C., Kim D., Davidson P., Kowdle A., Izadi S. Articulated distance fields for ultra-fast tracking of hands interacting // *ACM Transactions on Graphics*. 2017. V. 36. N. 6. P. 1–12. <https://doi.org/10.1145/3130800.3130853>
- Kindiroğlu A.A., Özdemir O., Akarun L. Temporal accumulative features for sign language recognition // Proc. of the IEEE/CVF International Conference on Computer Vision Workshop (ICCVW). 2019. P. 1288–1297. <https://doi.org/10.1109/ICCVW.2019.00164>
- Orbay A., Akarun L. Neural sign language translation by learning tokenization // Proc. of the 15<sup>th</sup> International Conference on Automatic Face and Gesture Recognition (FG). 2020. P. 222–228. <https://doi.org/10.1109/FG47880.2020.00002>
- Ryumin D., Ivanko D., Ryumina E., Ivanko D., Kashevnik A., Karpov A. Audio-visual speech and gesture recognition by sensors of mobile devices. *Sensors*, 2023, vol. 23, no. 4, pp. 2284. <https://doi.org/10.3390/s23042284>
- Axyonov A., Ryumin D., Ivanko D., Kashevnik A., Karpov A. Audio-visual speech recognition in-the-wild: multi-angle vehicle cabin corpus and attention-based method. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2024, pp. 8195–8199. <https://doi.org/10.1109/ICASSP48485.2024.10448048>
- Ma P., Haliassos A., Fernandez-Lopez A., Chen H., Petridis S., Pantic M. Auto-AVSR: audio-visual speech recognition with automatic labels. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2023, pp. 1–5. <https://doi.org/10.1109/ICASSP49357.2023.10096889>
- Wang X., Mi J., Li B., Zhao Y., Meng J. CATNet: Cross-modal fusion for audio-visual speech recognition. *Pattern Recognition Letters*, 2024, vol. 178, pp. 216–222. <https://doi.org/10.1016/j.patrec.2024.01.002>
- Ryumin D., Axyonov A., Ryumina E., Ivanko D., Kashevnik A., Karpov A. Audio-visual speech recognition based on regulated transformer and spatio-temporal fusion strategy for driver assistive systems. *Expert Systems with Applications*, 2024, vol. 252. part. A, pp. 124159. <https://doi.org/10.1016/j.eswa.2024.124159>
- Ryumin D., Karpov A. Towards automatic recognition of sign language gestures using kinect 2.0. *Lecture Notes in Computer Science*, 2017, vol. 10278, pp. 89–101. [https://doi.org/10.1007/978-3-319-58703-5\\_7](https://doi.org/10.1007/978-3-319-58703-5_7)
- Keskin C., Kiraç F., Kara Y.E., Akarun L. Hand pose estimation and hand shape classification using multi-layered randomized decision forests. *Lecture Notes in Computer Science*, 2012, vol. 7577, pp. 852–863. [https://doi.org/10.1007/978-3-642-33783-3\\_61](https://doi.org/10.1007/978-3-642-33783-3_61)
- Keskin C., Kiraç F., Kara Y.E., Akarun L. Real time hand pose estimation using depth sensors. *Consumer Depth Cameras for Computer Vision: Research Topics and Applications*, 2013, pp. 119–137. [https://doi.org/10.1007/978-1-4471-4640-7\\_7](https://doi.org/10.1007/978-1-4471-4640-7_7)
- Taylor J., Tankovich V., Tang D., Keskin C., Kim D., Davidson P., Kowdle A., Izadi S. Articulated distance fields for ultra-fast tracking of hands interacting. *ACM Transactions on Graphics*, 2017, vol. 36, no. 6, pp. 1–12. <https://doi.org/10.1145/3130800.3130853>
- Kindiroğlu A.A., Özdemir O., Akarun L. Temporal accumulative features for sign language recognition. *Proc. of the IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, 2019, pp. 1288–1297. <https://doi.org/10.1109/ICCVW.2019.00164>
- Orbay A., Akarun L. Neural sign language translation by learning tokenization. *Proc. of the 15<sup>th</sup> International Conference on Automatic Face and Gesture Recognition (FG)*, 2020, pp. 222–228. <https://doi.org/10.1109/FG47880.2020.00002>

## References

- Mehrish A., Majumder N., Bharadwaj R., Mihalcea R., Poria S. A review of deep learning techniques for speech processing // *Information Fusion*. 2023, vol. 99, pp. 101869. <https://doi.org/10.1016/j.inffus.2023.101869>
- Ryumin D., Ivanko D., Ryumina E. Audio-visual speech and gesture recognition by sensors of mobile devices. *Sensors*, 2023, vol. 23, no. 4, pp. 2284. <https://doi.org/10.3390/s23042284>
- Axyonov A., Ryumin D., Ivanko D., Kashevnik A., Karpov A. Audio-visual speech recognition in-the-wild: multi-angle vehicle cabin corpus and attention-based method. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2024, pp. 8195–8199. <https://doi.org/10.1109/ICASSP48485.2024.10448048>
- Ma P., Haliassos A., Fernandez-Lopez A., Chen H., Petridis S., Pantic M. Auto-AVSR: audio-visual speech recognition with automatic labels. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2023, pp. 1–5. <https://doi.org/10.1109/ICASSP49357.2023.10096889>
- Wang X., Mi J., Li B., Zhao Y., Meng J. CATNet: Cross-modal fusion for audio-visual speech recognition. *Pattern Recognition Letters*, 2024, vol. 178, pp. 216–222. <https://doi.org/10.1016/j.patrec.2024.01.002>
- Ryumin D., Axyonov A., Ryumina E., Ivanko D., Kashevnik A., Karpov A. Audio-visual speech recognition based on regulated transformer and spatio-temporal fusion strategy for driver assistive systems. *Expert Systems with Applications*, 2024, vol. 252. part. A, pp. 124159. <https://doi.org/10.1016/j.eswa.2024.124159>
- Ryumin D., Karpov A. Towards automatic recognition of sign language gestures using kinect 2.0. *Lecture Notes in Computer Science*, 2017, vol. 10278, pp. 89–101. [https://doi.org/10.1007/978-3-319-58703-5\\_7](https://doi.org/10.1007/978-3-319-58703-5_7)
- Keskin C., Kiraç F., Kara Y.E., Akarun L. Hand pose estimation and hand shape classification using multi-layered randomized decision forests. *Lecture Notes in Computer Science*, 2012, vol. 7577, pp. 852–863. [https://doi.org/10.1007/978-3-642-33783-3\\_61](https://doi.org/10.1007/978-3-642-33783-3_61)
- Keskin C., Kiraç F., Kara Y.E., Akarun L. Real time hand pose estimation using depth sensors. *Consumer Depth Cameras for Computer Vision: Research Topics and Applications*, 2013, pp. 119–137. [https://doi.org/10.1007/978-1-4471-4640-7\\_7](https://doi.org/10.1007/978-1-4471-4640-7_7)
- Taylor J., Tankovich V., Tang D., Keskin C., Kim D., Davidson P., Kowdle A., Izadi S. Articulated distance fields for ultra-fast tracking of hands interacting. *ACM Transactions on Graphics*, 2017, vol. 36, no. 6, pp. 1–12. <https://doi.org/10.1145/3130800.3130853>
- Kindiroğlu A.A., Özdemir O., Akarun L. Temporal accumulative features for sign language recognition. *Proc. of the IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, 2019, pp. 1288–1297. <https://doi.org/10.1109/ICCVW.2019.00164>
- Orbay A., Akarun L. Neural sign language translation by learning tokenization. *Proc. of the 15<sup>th</sup> International Conference on Automatic Face and Gesture Recognition (FG)*, 2020, pp. 222–228. <https://doi.org/10.1109/FG47880.2020.00002>

13. Camgoz N.C., Hadfield S., Koller O., Ney H., Bowden R. Neural sign language translation // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 7784–7793. <https://doi.org/10.1109/CVPR.2018.00812>
14. Koller O., Camgoz N.C., Ney H., Bowden R. Weakly supervised learning with multi-stream CNN-LSTM-HMMs to discover sequential parallelism in sign language videos // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2020. V. 42. N 9. P. 2306–2320. <https://doi.org/10.1109/TPAMI.2019.2911077>
15. Camgoz N.C., Koller O., Hadfield S., Bowden R. Multi-channel transformers for multi-articulatory sign language translation // Lecture Notes in Computer Science. 2020. V. 12538. P. 301–319. [https://doi.org/10.1007/978-3-030-66823-5\\_18](https://doi.org/10.1007/978-3-030-66823-5_18)
16. Narayana P., Beveridge J.R., Draper B.A. Gesture recognition: focus on the hands // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 5235–5244. <https://doi.org/10.1109/CVPR.2018.00549>
17. Zhu G., Zhang L., Shen P., Song J. Multimodal gesture recognition using 3-D convolution and convolutional LSTM // IEEE Access. 2017. V. 5. P. 4517–4524. <https://doi.org/10.1109/ACCESS.2017.2684186>
18. Abavisan M., Joze H.R.V., Patel V.M. Improving the performance of unimodal dynamic hand-gesture recognition with multimodal training // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2019. P. 1165–1174. <https://doi.org/10.1109/CVPR.2019.00126>
19. Elboushaki A., Hannane R., Afdel K., Koutti L. MultiD-CNN: A multi-dimensional feature learning approach based on deep convolutional networks for gesture recognition in RGB-D image sequences // Expert Systems with Applications. 2020. V. 139. P. 112829. <https://doi.org/10.1016/j.eswa.2019.112829>
20. Amangeldy N., Kudubayeva S., Kassymova A., Karipzhanova A., Razakhova B., Kuralov S. Sign language recognition method based on palm definition model and multiple classification // Sensors. 2022. V. 22. N 17. P. 6621. <https://doi.org/10.3390/s22176621>
21. Damaneh M.M., Mohanna F., Jafari P. Static hand gesture recognition in sign language based on convolutional neural network with feature extraction method using ORB descriptor and Gabor filter // Expert Systems with Applications. 2023. V. 211. P. 118559. <https://doi.org/10.1016/j.eswa.2022.118559>
22. Núñez-Marcos A., Perez-de-Viñaspre O., Labaka G. A survey on sign language machine translation // Expert Systems with Applications. 2023. V. 213. Part. B. P. 118993. <https://doi.org/10.1016/j.eswa.2022.118993>
23. Bohacek M., Hrúz M. Learning from what is already out there: few-shot sign language recognition with online dictionaries // Proc. of the 17<sup>th</sup> International Conference on Automatic Face and Gesture Recognition (FG). 2023. P. 1–6. <https://doi.org/10.1109/FG57933.2023.10042544>
24. Wei S.E., Ramakrishna V., Kanade T., Sheikh Y. Convolutional pose machines // Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 4724–4732. <https://doi.org/10.1109/CVPR.2016.511>
25. Naert L., Larboulette C., Gibet S. A survey on the animation of signing avatars: from sign representation to utterance synthesis // Computers and Graphics. 2020. V. 92. P. 76–98. <https://doi.org/10.1016/j.cag.2020.09.003>
26. Mujahid A., Awan M.J., Yasin A., Mohammed M.A., Damaševičius R., Maskeliūnas R., Abdulkareem K.H. Real-time hand gesture recognition based on deep learning YOLOv3 model // Applied Sciences. 2021. V. 11. N 9. P. 4164. <https://doi.org/10.3390/app11094164>
27. Wang Y., Yu B., Wang L., Zu C., Lalush D.S., Lin W., Wu X., Zhou J., Shen D., Zhou L. 3D conditional generative adversarial networks for high-quality PET image estimation at low dose // NeuroImage. 2018. V. 174. P. 550–562. <https://doi.org/10.1016/j.neuroimage.2018.03.045>
28. Vahdat A., Kautz J. NVAE: A deep hierarchical variational autoencoder // Proc. of the Neural Information Processing Systems (NeurIPS). 2020. P. 19667–19679.
29. Ma C., Guo Y., Yang J., An W. Learning multi-view representation with LSTM for 3-D shape recognition and retrieval // IEEE Transactions on Multimedia. 2019. V. 21. N 5. P. 1169–1182. <https://doi.org/10.1109/TMM.2018.2875512>
30. Vasileiadis M., Bouganis C.-S., Tzovaras D. Multi-person 3D pose estimation from 3D cloud data using 3D convolutional neural
13. Camgoz N.C., Hadfield S., Koller O., Ney H., Bowden R. Neural sign language translation. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 7784–7793. <https://doi.org/10.1109/CVPR.2018.00812>
14. Koller O., Camgoz N.C., Ney H., Bowden R. Weakly supervised learning with multi-stream CNN-LSTM-HMMs to discover sequential parallelism in sign language videos. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, vol. 42, no. 9, pp. 2306–2320. <https://doi.org/10.1109/TPAMI.2019.2911077>
15. Camgoz N.C., Koller O., Hadfield S., Bowden R. Multi-channel transformers for multi-articulatory sign language translation. *Lecture Notes in Computer Science*, 2020, vol. 12538, pp. 301–319. [https://doi.org/10.1007/978-3-030-66823-5\\_18](https://doi.org/10.1007/978-3-030-66823-5_18)
16. Narayana P., Beveridge J.R., Draper B.A. Gesture recognition: focus on the hands. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 5235–5244. <https://doi.org/10.1109/CVPR.2018.00549>
17. Zhu G., Zhang L., Shen P., Song J. Multimodal gesture recognition using 3-D convolution and convolutional LSTM. *IEEE Access*, 2017, vol. 5, pp. 4517–4524. <https://doi.org/10.1109/ACCESS.2017.2684186>
18. Abavisan M., Joze H.R.V., Patel V.M. Improving the performance of unimodal dynamic hand-gesture recognition with multimodal training. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 1165–1174. <https://doi.org/10.1109/CVPR.2019.00126>
19. Elboushaki A., Hannane R., Afdel K., Koutti L. MultiD-CNN: A multi-dimensional feature learning approach based on deep convolutional networks for gesture recognition in RGB-D image sequences. *Expert Systems with Applications*, 2020, vol. 139, pp. 112829. <https://doi.org/10.1016/j.eswa.2019.112829>
20. Amangeldy N., Kudubayeva S., Kassymova A., Karipzhanova A., Razakhova B., Kuralov S. Sign language recognition method based on palm definition model and multiple classification. *Sensors*, 2022, vol. 22, no. 17, pp. 6621. <https://doi.org/10.3390/s22176621>
21. Damaneh M.M., Mohanna F., Jafari P. Static hand gesture recognition in sign language based on convolutional neural network with feature extraction method using ORB descriptor and Gabor filter. *Expert Systems with Applications*, 2023, vol. 211, pp. 118559. <https://doi.org/10.1016/j.eswa.2022.118559>
22. Núñez-Marcos A., Perez-de-Viñaspre O., Labaka G. A survey on sign language machine translation. *Expert Systems with Applications*, 2023, vol. 213, part. B, pp. 118993. <https://doi.org/10.1016/j.eswa.2022.118993>
23. Bohacek M., Hrúz M. Learning from what is already out there: few-shot sign language recognition with online dictionaries. *Proc. of the 17<sup>th</sup> International Conference on Automatic Face and Gesture Recognition (FG)*, 2023, pp. 1–6. <https://doi.org/10.1109/FG57933.2023.10042544>
24. Wei S.E., Ramakrishna V., Kanade T., Sheikh Y. Convolutional pose machines. *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 4724–4732. <https://doi.org/10.1109/CVPR.2016.511>
25. Naert L., Larboulette C., Gibet S. A survey on the animation of signing avatars: from sign representation to utterance synthesis. *Computers and Graphics*, 2020, vol. 92, pp. 76–98. <https://doi.org/10.1016/j.cag.2020.09.003>
26. Mujahid A., Awan M.J., Yasin A., Mohammed M.A., Damaševičius R., Maskeliūnas R., Abdulkareem K.H. Real-time hand gesture recognition based on deep learning YOLOv3 model. *Applied Sciences*, 2021, vol. 11, no. 9, pp. 4164. <https://doi.org/10.3390/app11094164>
27. Wang Y., Yu B., Wang L., Zu C., Lalush D.S., Lin W., Wu X., Zhou J., Shen D., Zhou L. 3D conditional generative adversarial networks for high-quality PET image estimation at low dose. *NeuroImage*, 2018, vol. 174, pp. 550–562. <https://doi.org/10.1016/j.neuroimage.2018.03.045>
28. Vahdat A., Kautz J. NVAE: A deep hierarchical variational autoencoder. *Proc. of the Neural Information Processing Systems (NeurIPS)*, 2020, pp. 19667–19679.
29. Ma C., Guo Y., Yang J., An W. Learning multi-view representation with LSTM for 3-D shape recognition and retrieval. *IEEE Transactions on Multimedia*, 2019, vol. 21, no. 5, pp. 1169–1182. <https://doi.org/10.1109/TMM.2018.2875512>
30. Vasileiadis M., Bouganis C.-S., Tzovaras D. Multi-person 3D pose estimation from 3D cloud data using 3D convolutional neural

- nets // Computer Vision and Image Understanding. 2019. V. 185. P. 12–23. <https://doi.org/10.1016/j.cviu.2019.04.011>
31. Lin J., Yuan Y., Shao T., Zhou K. Towards high-fidelity 3D face reconstruction from in-the-wild images using graph convolutional networks // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. P. 5890–5900. <https://doi.org/10.1109/cvpr42600.2020.00593>
  32. Liu R., Shen J., Wang H., Chen C., Cheung S.-C., Asari V. Attention mechanism exploits temporal contexts: real-time 3D human pose reconstruction // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. P. 5063–5072. <https://doi.org/10.1109/cvpr42600.2020.00511>
  33. Zhang Z., Sun L., Yang Z., Chen L., Yang Y. Global-correlated 3D-decoupling transformer for clothed avatar reconstruction // Proc. of the Neural Information Processing Systems (NeurIPS). 2023. P. 7818–7830.
  34. Dupont S., Luettin J. Audio-visual speech modeling for continuous speech recognition // IEEE Transactions on Multimedia. 2000. V. 2. N 3. P. 141–151. <https://doi.org/10.1109/6046.865479>
  35. Ivanko D., Ryumin D., Axyonov A., Kashevnik A. Speaker-dependent visual command recognition in vehicle cabin: methodology and evaluation // Lecture Notes in Computer Science. 2021. V. 12997. P. 291–302. [https://doi.org/10.1007/978-3-030-87802-3\\_27](https://doi.org/10.1007/978-3-030-87802-3_27)
  36. Ivanko D., Ryumin D., Kipyatkova I., Axyonov A., Karpov A. Lip-reading using pixel-based and geometry-based features for multimodal human-robot interfaces // Smart Innovation, Systems and Technologies. 2020. V. 154. P. 477–486. [https://doi.org/10.1007/978-981-13-9267-2\\_39](https://doi.org/10.1007/978-981-13-9267-2_39)
  37. Аксенов А.А., Рюмина Е.В., Рюмин Д.А., Иванько Д.В., Карпов А.А. Нейросетевой метод визуального распознавания голосовых команд водителя с использованием механизма внимания // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 4. С. 767–775. <https://doi.org/10.17586/2226-1494-2023-23-4-767-775>
  38. Petridis S., Pantic M. Deep complementary bottleneck features for visual speech recognition // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2016. P. 2304–2308. <https://doi.org/10.1109/ICASSP.2016.7472088>
  39. Takashima Y., Aihara R., Takiguchi T., Ariki Y., Mitani N., Omori K., Nakazono K. Audio-visual speech recognition using bimodal-trained bottleneck features for a person with severe hearing loss // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2016. P. 277–281. <https://doi.org/10.21437/Interspeech.2016-721>
  40. Ninomiya H., Kitaoka N., Tamura S., Iribe Y., Takeda K. Integration of deep bottleneck features for audio-visual speech recognition // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2015. P. 563–567. <https://doi.org/10.21437/Interspeech.2015-204>
  41. Ivanko D., Ryumin D., Karpov A. A review of recent advances on deep learning methods for audio-visual speech recognition // Mathematics. 2023. V. 11. N 12. P. 2665. <https://doi.org/10.3390/math11122665>
  42. Ma P., Petridis S., Pantic M. End-to-end audio-visual speech recognition with conformers // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2021. P. 7613–7617. <https://doi.org/10.1109/ICASSP39728.2021.9414567>
  43. Hong J., Kim M., Choi J., Ro Y.M. Watch or listen: Robust audio-visual speech recognition with visual corruption modeling and reliability scoring // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2023. P. 18783–18794. <https://doi.org/10.1109/CVPR52729.2023.01801>
  44. Li G., Deng J., Geng M., Jin Z., Wang T., Hu S., Cui M., Meng H., Liu X. Audio-visual end-to-end multi-channel speech separation, dereverberation and recognition // IEEE/ACM Transactions on Audio, Speech, and Language Processing. 2023. V. 31. P. 2707–2723. <https://doi.org/10.1109/TASLP.2023.3294705>
  45. Burchi M., Timofte R. Audio-visual efficient conformer for robust speech recognition // Proc. of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). 2023. P. 2257–2266. <https://doi.org/10.1109/WACV56688.2023.00229>
  46. Chang O., Liao H., Serdyuk D., Shahy A., Siohan O. Conformer is all you need for visual speech recognition // Proc. of the International Conference on Acoustics, Speech and Signal Processing (ICASSP). networks. *Computer Vision and Image Understanding*, 2019, vol. 185, pp. 12–23. <https://doi.org/10.1016/j.cviu.2019.04.011>
  31. Lin J., Yuan Y., Shao T., Zhou K. Towards high-fidelity 3D face reconstruction from in-the-wild images using graph convolutional networks. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, pp. 5890–5900. <https://doi.org/10.1109/cvpr42600.2020.00593>
  32. Liu R., Shen J., Wang H., Chen C., Cheung S.-C., Asari V. Attention mechanism exploits temporal contexts: real-time 3D human pose reconstruction. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, pp. 5063–5072. <https://doi.org/10.1109/cvpr42600.2020.00511>
  33. Zhang Z., Sun L., Yang Z., Chen L., Yang Y. Global-correlated 3D-decoupling transformer for clothed avatar reconstruction. *Proc. of the Neural Information Processing Systems (NeurIPS)*, 2023, pp. 7818–7830.
  34. Dupont S., Luettin J. Audio-visual speech modeling for continuous speech recognition. *IEEE Transactions on Multimedia*, 2000, vol. 2, no. 3, pp. 141–151. <https://doi.org/10.1109/6046.865479>
  35. Ivanko D., Ryumin D., Axyonov A., Kashevnik A. Speaker-dependent visual command recognition in vehicle cabin: methodology and evaluation. *Lecture Notes in Computer Science*, 2021, vol. 12997, pp. 291–302. [https://doi.org/10.1007/978-3-030-87802-3\\_27](https://doi.org/10.1007/978-3-030-87802-3_27)
  36. Ivanko D., Ryumin D., Kipyatkova I., Axyonov A., Karpov A. Lip-reading using pixel-based and geometry-based features for multimodal human-robot interfaces. *Smart Innovation, Systems and Technologies*, 2020, vol. 154, pp. 477–486. [https://doi.org/10.1007/978-981-13-9267-2\\_39](https://doi.org/10.1007/978-981-13-9267-2_39)
  37. Axyonov A.A., Ryumina E.V., Ryumin D.A., Ivanko D.V., Karpov A.A. Neural network-based method for visual recognition of driver's voice commands using attention mechanism. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2023, vol. 23, no. 4, pp. 767–775. (in Russian). <https://doi.org/10.17586/2226-1494-2023-23-4-767-775>
  38. Petridis S., Pantic M. Deep complementary bottleneck features for visual speech recognition. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2016, pp. 2304–2308. <https://doi.org/10.1109/ICASSP.2016.7472088>
  39. Takashima Y., Aihara R., Takiguchi T., Ariki Y., Mitani N., Omori K., Nakazono K. Audio-visual speech recognition using bimodal-trained bottleneck features for a person with severe hearing loss. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2016, pp. 277–281. <https://doi.org/10.21437/Interspeech.2016-721>
  40. Ninomiya H., Kitaoka N., Tamura S., Iribe Y., Takeda K. Integration of deep bottleneck features for audio-visual speech recognition. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2015, pp. 563–567. <https://doi.org/10.21437/Interspeech.2015-204>
  41. Ivanko D., Ryumin D., Karpov A. A review of recent advances on deep learning methods for audio-visual speech recognition. *Mathematics*, 2023, vol. 11, no. 12, pp. 2665. <https://doi.org/10.3390/math11122665>
  42. Ma P., Petridis S., Pantic M. End-to-end audio-visual speech recognition with conformers. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2021, pp. 7613–7617. <https://doi.org/10.1109/ICASSP39728.2021.9414567>
  43. Hong J., Kim M., Choi J., Ro Y.M. Watch or listen: Robust audio-visual speech recognition with visual corruption modeling and reliability scoring. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2023, pp. 18783–18794. <https://doi.org/10.1109/CVPR52729.2023.01801>
  44. Li G., Deng J., Geng M., Jin Z., Wang T., Hu S., Cui M., Meng H., Liu X. Audio-visual end-to-end multi-channel speech separation, dereverberation and recognition. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2023, vol. 31, pp. 2707–2723. <https://doi.org/10.1109/TASLP.2023.3294705>
  45. Burchi M., Timofte R. Audio-visual efficient conformer for robust speech recognition. *Proc. of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, 2023, pp. 2257–2266. <https://doi.org/10.1109/WACV56688.2023.00229>
  46. Chang O., Liao H., Serdyuk D., Shahy A., Siohan O. Conformer is all you need for visual speech recognition. *Proc. of the International Conference on Acoustics, Speech and Signal Processing (ICASSP)*,

2024. P. 10136–10140. <https://doi.org/10.1109/icassp48485.2024.10446532>
47. Wand M., Koutnik J., Schmidhuber J. Lipreading with long short-term memory // Proc. of the International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2016. P. 6115–6119. <https://doi.org/10.1109/ICASSP.2016.7472852>
48. Assael Y.M., Shillingford B., Whiteson S., De Freitas N. LipNet: end-to-end sentence-level lipreading // arXiv. 2016. arXiv:1611.01599. <https://doi.org/10.48550/arXiv.1611.01599>
49. Shi B., Hsu W.N., Mohamed A. Robust self-supervised audio-visual speech recognition // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2022. P. 2118–2122. <https://doi.org/10.21437/interspeech.2022-99>
50. Ivanko D., Ryumin D., Kashevnik A.M., Axyonov A., Kitenko A., Lashkov I., Karpov A. DAVIS: driver's audio-visual speech recognition // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2022. P. 1141–1142.
51. Zhou P., Yang W., Chen W., Wang Y., Jia J. Modality attention for end-to-end audio-visual speech recognition // Proc. of the International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2019. P. 6565–6569. <https://doi.org/10.1109/ICASSP.2019.8683733>
52. Makino T., Liao H., Assael Y., Shillingford B., Garcia B., Braga O., Siohan O. Recurrent neural network transducer for audio-visual speech recognition // Proc. of the IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). 2019. P. 905–912. <https://doi.org/10.1109/ASRU46091.2019.9004036>
53. Li J., Li C., Wu Y., Qian Y. Unified cross-modal attention: robust audio-visual speech recognition and beyond // IEEE/ACM Transactions on Audio, Speech, and Language Processing. 2024. V. 32. P. 1941–1953. <https://doi.org/10.1109/TASLP.2024.3375641>
54. Tan X., Qin T., Soong F., Liu T.Y. A survey on neural speech synthesis // arXiv. 2021. arXiv:2106.15561. <https://doi.org/10.48550/arXiv.2106.15561>
55. de Barcelos Silva A., Gomes M.M., da Costa C.A., da Rosa Righi R., Barbosa J.L.V., Pessin G., de Doncker G., Federizzi G. Intelligent personal assistants: a systematic literature review // Expert Systems with Applications. 2020. V. 147. P. 113193. <https://doi.org/10.1016/j.eswa.2020.113193>
56. Oord A., Li Y., Babuschkin I., Simonyan K., Vinyals O., Kavukcuoglu K., Driessche G., Lockhart E., Cobo L., Stimberg F., Casagrande N., Grewe D., Noury S., Dieleman S., Elsen E., Kalchbrenner N., Zen H., Graves A., King H., Walters T., Belov D., Hassabis D. Parallel wavenet: fast high-fidelity speech synthesis // Proc. of the 35<sup>th</sup> International Conference on Machine Learning (ICML). 2018. P. 3918–3926.
57. Wang Y., Skerry-Ryan R.J., Stanton D., Wu Y., Weiss R.J., Jaityl N., Yang Z., Xiao Y., Chen Z., Bengio S., Le Q., Agiomirgianakis Y., Clark R., Saurous R.A. Tacotron: towards end-to-end speech synthesis // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2017. P. 4006–4010. <https://doi.org/10.21437/Interspeech.2017-1452>
58. Arik S.Ö., Chrzanowski M., Coates A., Diamos G., Gibiansky A., Kang Y., Li X., Miller J., Ng A., Raiman J., Sengupta S., Shoeybi M. Deep voice: real-time neural text-to-speech // Proc. of the 34<sup>th</sup> International Conference on Machine Learning (ICML). 2017. P. 195–204.
59. Li N., Liu S., Liu Y., Zhao S., Liu M. Neural speech synthesis with transformer network // Proc. of the AAAI Conference on Artificial Intelligence. 2019. V. 33. N 1. P. 6706–6713. <https://doi.org/10.1609/AAAI.V33I01.33016706>
60. Ren Y., Ruan Y., Tan X., Qin T., Zhao S., Zhao Z., Liu T.Y. Fastspeech: fast, robust and controllable text to speech // Proc. of the Neural Information Processing Systems (NeurIPS). 2019. P. 1–10.
61. Prenger R., Valle R., Catanzaro B. Waveglow: a flow-based generative network for speech synthesis // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2019. P. 3617–3621. <https://doi.org/10.1109/ICASSP.2019.8683143>
62. Kumar K., Kumar R., De Boissiere T., Gestin L., Teoh W.Z., Sotelo J., de Brébisson A., Bengio Y., Courville A.C. Melgan: generative adversarial networks for conditional waveform synthesis // Proc. of the Neural Information Processing Systems (NeurIPS). 2019. P. 320–335.
63. Yamamoto R., Song E., Kim J.M. Parallel WaveGAN: a fast waveform generation model based on generative adversarial networks with multi-resolution spectrogram. Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2024, pp. 10136–10140. <https://doi.org/10.1109/icassp48485.2024.10446532>
47. Wand M., Koutnik J., Schmidhuber J. Lipreading with long short-term memory. Proc. of the International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2016, pp. 6115–6119. <https://doi.org/10.1109/ICASSP.2016.7472852>
48. Assael Y.M., Shillingford B., Whiteson S., De Freitas N. LipNet: end-to-end sentence-level lipreading. arXiv, 2016. arXiv:1611.01599. <https://doi.org/10.48550/arXiv.1611.01599>
49. Shi B., Hsu W.N., Mohamed A. Robust self-supervised audio-visual speech recognition. Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH, 2022, pp. 2118–2122. <https://doi.org/10.21437/interspeech.2022-99>
50. Ivanko D., Ryumin D., Kashevnik A.M., Axyonov A., Kitenko A., Lashkov I., Karpov A. DAVIS: driver's audio-visual speech recognition. Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH, 2022, pp. 1141–1142.
51. Zhou P., Yang W., Chen W., Wang Y., Jia J. Modality attention for end-to-end audio-visual speech recognition. Proc. of the International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2019, pp. 6565–6569. <https://doi.org/10.1109/ICASSP.2019.8683733>
52. Makino T., Liao H., Assael Y., Shillingford B., Garcia B., Braga O., Siohan O. Recurrent neural network transducer for audio-visual speech recognition. Proc. of the IEEE Automatic Speech Recognition and Understanding Workshop (ASRU), 2019, pp. 905–912. <https://doi.org/10.1109/ASRU46091.2019.9004036>
53. Li J., Li C., Wu Y., Qian Y. Unified cross-modal attention: robust audio-visual speech recognition and beyond. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2024, vol. 32, pp. 1941–1953. <https://doi.org/10.1109/TASLP.2024.3375641>
54. Tan X., Qin T., Soong F., Liu T.Y. A survey on neural speech synthesis. arXiv, 2021. arXiv:2106.15561. <https://doi.org/10.48550/arXiv.2106.15561>
55. de Barcelos Silva A., Gomes M.M., da Costa C.A., da Rosa Righi R., Barbosa J.L.V., Pessin G., de Doncker G., Federizzi G. Intelligent personal assistants: a systematic literature review. Expert Systems with Applications, 2020, vol. 147, pp. 113193. <https://doi.org/10.1016/j.eswa.2020.113193>
56. Oord A., Li Y., Babuschkin I., Simonyan K., Vinyals O., Kavukcuoglu K., Driessche G., Lockhart E., Cobo L., Stimberg F., Casagrande N., Grewe D., Noury S., Dieleman S., Elsen E., Kalchbrenner N., Zen H., Graves A., King H., Walters T., Belov D., Hassabis D. Parallel wavenet: fast high-fidelity speech synthesis. Proc. of the 35<sup>th</sup> International Conference on Machine Learning (ICML), 2018, pp. 3918–3926.
57. Wang Y., Skerry-Ryan R.J., Stanton D., Wu Y., Weiss R.J., Jaityl N., Yang Z., Xiao Y., Chen Z., Bengio S., Le Q., Agiomirgianakis Y., Clark R., Saurous R.A. Tacotron: towards end-to-end speech synthesis. Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH, 2017, pp. 4006–4010. <https://doi.org/10.21437/Interspeech.2017-1452>
58. Arik S.Ö., Chrzanowski M., Coates A., Diamos G., Gibiansky A., Kang Y., Li X., Miller J., Ng A., Raiman J., Sengupta S., Shoeybi M. Deep voice: real-time neural text-to-speech. Proc. of the 34<sup>th</sup> International Conference on Machine Learning (ICML), 2017, pp. 195–204.
59. Li N., Liu S., Liu Y., Zhao S., Liu M. Neural speech synthesis with transformer network. Proc. of the AAAI Conference on Artificial Intelligence, 2019, vol. 33, no. 1, pp. 6706–6713. <https://doi.org/10.1609/AAAI.V33I01.33016706>
60. Ren Y., Ruan Y., Tan X., Qin T., Zhao S., Zhao Z., Liu T.Y. Fastspeech: fast, robust and controllable text to speech. Proc. of the Neural Information Processing Systems (NeurIPS), 2019, pp. 1–10.
61. Prenger R., Valle R., Catanzaro B. Waveglow: a flow-based generative network for speech synthesis. Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2019, pp. 3617–3621. <https://doi.org/10.1109/ICASSP.2019.8683143>
62. Kumar K., Kumar R., De Boissiere T., Gestin L., Teoh W.Z., Sotelo J., de Brébisson A., Bengio Y., Courville A.C. Melgan: generative adversarial networks for conditional waveform synthesis. Proc. of the Neural Information Processing Systems (NeurIPS), 2019, pp. 320–335.
63. Yamamoto R., Song E., Kim J.M. Parallel WaveGAN: a fast waveform generation model based on generative adversarial networks with multi-resolution spectrogram. Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2024, pp. 10136–10140. <https://doi.org/10.1109/icassp48485.2024.10446532>

- with multi-resolution spectrogram // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2020. P. 6199–6203. <https://doi.org/10.1109/ICASSP40776.2020.9053795>
64. Valin J.M., Skoglund J. LPCNet: Improving neural speech synthesis through linear prediction // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2019. P. 5891–5895. <https://doi.org/10.1109/icassp.2019.8682804>
  65. Asimopoulos D.C., Nitsiou M., Lazaridis L., Fragulis G.F. Generative adversarial networks: a systematic review and applications // SHS Web of Conferences. 2022. V. 139. P. 03012. <https://doi.org/10.1051/shsconf/202213903012>
  66. Kong J., Kim J., Bae J. Hifi-gan: generative adversarial networks for efficient and high fidelity speech synthesis // Proc. of the Neural Information Processing Systems (NeurIPS). 2020. P. 17022–17033.
  67. Fang W., Chung Y.A., Glass J. Towards transfer learning for end-to-end speech synthesis from deep pre-trained language models // arXiv. 2019. arXiv:1906.07307. <https://doi.org/10.48550/arXiv.1906.07307>
  68. Valle R., Shih K., Prenger R., Catanzaro B. Flowtron: an autoregressive flow-based generative network for text-to-speech synthesis // Proc. of the 9th International Conference on Learning Representations (ICLR). 2021. P. 1–6.
  69. Chen N., Zhang Y., Zen H., Weiss R.J., Norouzi M., Chan W. Wavegrad: estimating gradients for waveform generation // Proc. of the 9th International Conference on Learning Representations (ICLR). 2021. P. 1–8.
  70. Ping W., Peng K., Chen J. Clarinet: Parallel wave generation in end-to-end text-to-speech // Proc. of the 7th International Conference on Learning Representations (ICLR). 2019. P. 1–7.
  71. Camgöz N.C., Koller O., Hadfield S., Bowden R. Sign language transformers: joint end-to-end sign language recognition and translation // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. P. 10020–10030. <https://doi.org/10.1109/CVPR42600.2020.01004>
  72. Bragg D., Koller O., Caselli N., Thies W. Exploring collection of sign language datasets: privacy, participation, and model performance // Proc. of the 22nd International ACM SIGACCESS Conference on Computers and Accessibility. 2020. P. 1–14. <https://doi.org/10.1145/3373625.3417024>
  73. Caselli N.K., Sehyr Z.S., Cohen-Goldberg A.M., Emmorey K. ASL-LEX: a lexical database of american sign language // Behavior Research Methods. 2017. V. 49. N 2. P. 784–801. <https://doi.org/10.3758/s13428-016-0742-0>
  74. Forster J., Schmidt C., Koller O., Bellgardt M., Ney H. Extensions of the sign language recognition and translation corpus RWTH-PHOENIX-Weather // Proc. of the 9th International Conference on Language Resources and Evaluation (LREC). 2014. P. 1911–1916.
  75. Azad R., Asadi-Aghbolaghi M., Kasaei S., Escalera S. Dynamic 3D hand gesture recognition by learning weighted depth motion maps // IEEE Transactions on Circuits and Systems for Video Technology. 2019. V. 29. N 6. P. 1729–1740. <https://doi.org/10.1109/TCSVT.2018.2855416>
  76. Chen Y., Wei F., Sun X., Wu Z., Lin S. A simple multi-modality transfer learning baseline for sign language translation // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 5110–5120. <https://doi.org/10.1109/CVPR52688.2022.00506>
  77. Escalera S., Baró X., González J., Bautista M.A., Madadi M., Reyes M., Ponce-López V., Escalante H.J., Shotton J., Guyon I. ChaLearn looking at people challenge 2014: dataset and results // Lecture Notes in Computer Science. 2015. V. 8925. P. 459–473. [https://doi.org/10.1007/978-3-319-16178-5\\_32](https://doi.org/10.1007/978-3-319-16178-5_32)
  78. Kagirov I., Ivanko D., Ryumin D., Axyonov A., Karpov A. TheRuSLan: database of russian sign language // Proc. of the 12th International Conference on Language Resources and Evaluation (LREC). 2020. P. 6079–6085.
  79. Sincan O.M., Keles H.Y. AUTSL: a large scale multi-modal turkish sign language dataset and baseline methods // IEEE Access. 2020. V. 8. P. 181340–181355. <https://doi.org/10.1109/ACCESS.2020.3028072>
  80. Kapitanov A., Kvanchiani K., Nagaev A., Kraynov R., Makhliarchuk A. HaGRID — HAnd gesture recognition image dataset // Proc. of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). 2024. P. 4560–4569. <https://doi.org/10.1109/WACV57701.2024.00451>
  81. Petridis S., Wang Y., Ma P., Li Z., Pantic M. End-to-end visual speech recognition for small-scale datasets. *Pattern Recognition Letters*, Conference on Acoustics, Speech and Signal Processing (ICASSP), 2020, pp. 6199–6203. <https://doi.org/10.1109/ICASSP40776.2020.9053795>
  82. Valin J.M., Skoglund J. LPCNet: Improving neural speech synthesis through linear prediction. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 5891–5895. <https://doi.org/10.1109/icassp.2019.8682804>
  83. Asimopoulos D.C., Nitsiou M., Lazaridis L., Fragulis G.F. Generative adversarial networks: a systematic review and applications. *SHS Web of Conferences*, 2022, vol. 139, pp. 03012. <https://doi.org/10.1051/shsconf/202213903012>
  84. Kong J., Kim J., Bae J. Hifi-gan: generative adversarial networks for efficient and high fidelity speech synthesis. *Proc. of the Neural Information Processing Systems (NeurIPS)*, 2020, pp. 17022–17033.
  85. Fang W., Chung Y.A., Glass J. Towards transfer learning for end-to-end speech synthesis from deep pre-trained language models. *arXiv*, 2019, arXiv:1906.07307. <https://doi.org/10.48550/arXiv.1906.07307>
  86. Valle R., Shih K., Prenger R., Catanzaro B. Flowtron: an autoregressive flow-based generative network for text-to-speech synthesis. *Proc. of the 9th International Conference on Learning Representations (ICLR)*, 2021, pp. 1–6.
  87. Chen N., Zhang Y., Zen H., Weiss R.J., Norouzi M., Chan W. Wavegrad: estimating gradients for waveform generation. *Proc. of the 9th International Conference on Learning Representations (ICLR)*, 2021, pp. 1–8.
  88. Ping W., Peng K., Chen J. Clarinet: Parallel wave generation in end-to-end text-to-speech. *Proc. of the 7th International Conference on Learning Representations (ICLR)*, 2019, pp. 1–7.
  89. Camgöz N.C., Koller O., Hadfield S., Bowden R. Sign language transformers: joint end-to-end sign language recognition and translation. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, pp. 10020–10030. <https://doi.org/10.1109/CVPR42600.2020.01004>
  90. Bragg D., Koller O., Caselli N., Thies W. Exploring collection of sign language datasets: privacy, participation, and model performance. *Proc. of the 22nd International ACM SIGACCESS Conference on Computers and Accessibility*, 2020, pp. 1–14. <https://doi.org/10.1145/3373625.3417024>
  91. Caselli N.K., Sehyr Z.S., Cohen-Goldberg A.M., Emmorey K. ASL-LEX: a lexical database of american sign language. *Behavior Research Methods*, 2017, vol. 49, no. 2, pp. 784–801. <https://doi.org/10.3758/s13428-016-0742-0>
  92. Forster J., Schmidt C., Koller O., Bellgardt M., Ney H. Extensions of the sign language recognition and translation corpus RWTH-PHOENIX-Weather. *Proc. of the 9th International Conference on Language Resources and Evaluation (LREC)*, 2014, pp. 1911–1916.
  93. Azad R., Asadi-Aghbolaghi M., Kasaei S., Escalera S. Dynamic 3D hand gesture recognition by learning weighted depth motion maps. *IEEE Transactions on Circuits and Systems for Video Technology*, 2019, vol. 29, no. 6, pp. 1729–1740. <https://doi.org/10.1109/TCSVT.2018.2855416>
  94. Chen Y., Wei F., Sun X., Wu Z., Lin S. A simple multi-modality transfer learning baseline for sign language translation. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 5110–5120. <https://doi.org/10.1109/CVPR52688.2022.00506>
  95. Escalera S., Baró X., González J., Bautista M.A., Madadi M., Reyes M., Ponce-López V., Escalante H.J., Shotton J., Guyon I. ChaLearn looking at people challenge 2014: dataset and results. *Lecture Notes in Computer Science*, 2015, vol. 8925, pp. 459–473. [https://doi.org/10.1007/978-3-319-16178-5\\_32](https://doi.org/10.1007/978-3-319-16178-5_32)
  96. Kagirov I., Ivanko D., Ryumin D., Axyonov A., Karpov A. TheRuSLan: database of russian sign language. *Proc. of the 12th International Conference on Language Resources and Evaluation (LREC)*, 2020, pp. 6079–6085.
  97. Sincan O.M., Keles H.Y. AUTSL: a large scale multi-modal turkish sign language dataset and baseline methods. *IEEE Access*, 2020, vol. 8, pp. 181340–181355. <https://doi.org/10.1109/ACCESS.2020.3028072>
  98. Kapitanov A., Kvanchiani K., Nagaev A., Kraynov R., Makhliarchuk A. HaGRID – HAnd gesture recognition image dataset. *Proc. of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, 2024, pp. 4560–4569. <https://doi.org/10.1109/WACV57701.2024.00451>
  99. Petridis S., Wang Y., Ma P., Li Z., Pantic M. End-to-end visual speech recognition for small-scale datasets. *Pattern Recognition Letters*,

81. Petridis S., Wang Y., Ma P., Li Z., Pantic M. End-to-end visual speech recognition for small-scale datasets // Pattern Recognition Letters. 2020. V. 131. P. 421–427. <https://doi.org/10.1016/j.patrec.2020.01.022>
82. Cooke M., Barker J., Cunningham S., Shao X. An audio-visual corpus for speech perception and automatic speech recognition // The Journal of the Acoustical Society of America. 2006. V. 120. N 5. P. 2421–2424. <https://doi.org/10.1121/1.2229005>
83. Chung J.S., Zisserman A. Lip reading in the wild // Lecture Notes in Computer Science. 2017. V. 10112. P. 87–103. [https://doi.org/10.1007/978-3-319-54184-6\\_6](https://doi.org/10.1007/978-3-319-54184-6_6)
84. Sequeira A.F., Monteiro J.C., Rebelo A., Oliveira H.P. MobBIO: a multimodal database captured with a portable handheld device // Proc. of the 9<sup>th</sup> International Conference on Computer Vision Theory and Applications (VISAPP). 2014. P. 133–139. <https://doi.org/10.5220/0004679601330139>
85. Parekh D., Gupta A., Chhatpar S., Yash A., Kulkarni M. Lip reading using convolutional auto encoders as feature extractor // Proc. of the IEEE 5<sup>th</sup> International Conference for Convergence in Technology (I2CT). 2019. P. 1–6. <https://doi.org/10.1109/I2CT4561.2019.9033664>
86. Leeson L., Sheikh H. SIGNALL: a european partnership approach to deaf studies via new technologies // Proc. of the INTED. 2009. P. 1270–1279.
87. Loizides F., Basson S., Kanevsky D., Prilepova O., Savla S., Zaraysky S. Breaking boundaries with live transcribe: expanding use cases beyond standard captioning scenarios // Proc. of the 22<sup>nd</sup> International ACM SIGACCESS Conference on Computers and Accessibility. 2020. P. 1–6. <https://doi.org/10.1145/3373625.3417300>
88. Sinha A., Choi C., Ramani K. DeepHand: robust hand pose estimation by completing a matrix imputed with deep features // Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 4150–4158. <https://doi.org/10.1109/CVPR.2016.450>
89. Ee L.W.S., Ramachandiran C.R., Logeswaran R. Real-time sign language learning system // Journal of Physics: Conference Series. 2020. V. 1712. P. 12011. <https://doi.org/10.1088/1742-6596/1712/1/012011>
90. Junczys-Dowmunt M. Microsoft translator at wmt 2019: towards large-scale document-level neural machine translation // Proc. of the Conference on Machine Translation. 2019. P. 225–233. <https://doi.org/10.18653/v1/W19-5321>
91. Hong F., You S., Wei M., Zhang Y., Guo Z. MGRA: motion gesture recognition via accelerometer // Sensors. 2016. V. 16. N 4. P. 530. <https://doi.org/10.3390/s16040530>
92. Chung J.S., Zisserman A. Lip reading in the wild. Lecture Notes in Computer Science, 2017, vol. 10112, pp. 87–103. [https://doi.org/10.1007/978-3-319-54184-6\\_6](https://doi.org/10.1007/978-3-319-54184-6_6)
93. Sequeira A.F., Monteiro J.C., Rebelo A., Oliveira H.P. MobBIO: a multimodal database captured with a portable handheld device. Proc. of the 9<sup>th</sup> International Conference on Computer Vision Theory and Applications (VISAPP), 2014, pp. 133–139. <https://doi.org/10.5220/0004679601330139>
94. Parekh D., Gupta A., Chhatpar S., Yash A., Kulkarni M. Lip reading using convolutional auto encoders as feature extractor. Proc. of the IEEE 5<sup>th</sup> International Conference for Convergence in Technology (I2CT), 2019, pp. 1–6. <https://doi.org/10.1109/I2CT4561.2019.9033664>
95. Leeson L., Sheikh H. SIGNALL: a european partnership approach to deaf studies via new technologies. Proc. of the INTED, 2009, pp. 1270–1279.
96. Loizides F., Basson S., Kanevsky D., Prilepova O., Savla S., Zaraysky S. Breaking boundaries with live transcribe: expanding use cases beyond standard captioning scenarios. Proc. of the 22<sup>nd</sup> International ACM SIGACCESS Conference on Computers and Accessibility, 2020, pp. 1–6. <https://doi.org/10.1145/3373625.3417300>
97. Sinha A., Choi C., Ramani K. DeepHand: robust hand pose estimation by completing a matrix imputed with deep features. Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 4150–4158. <https://doi.org/10.1109/CVPR.2016.450>
98. Ee L.W.S., Ramachandiran C.R., Logeswaran R. Real-time sign language learning system. Journal of Physics: Conference Series, 2020, vol. 1712, pp. 12011. <https://doi.org/10.1088/1742-6596/1712/1/012011>
99. Junczys-Dowmunt M. Microsoft translator at wmt 2019: towards large-scale document-level neural machine translation. Proc. of the Conference on Machine Translation, 2019, pp. 225–233. <https://doi.org/10.18653/v1/W19-5321>
100. Hong F., You S., Wei M., Zhang Y., Guo Z. MGRA: motion gesture recognition via accelerometer. Sensors, 2016, vol. 16, no. 4, pp. 530. <https://doi.org/10.3390/s16040530>

## Авторы

**Иванько Денис Викторович** — кандидат технических наук, старший научный сотрудник, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук, Санкт-Петербург, 199178, Российская Федерация, <https://orcid.org/0000-0003-0412-7765>, ivanko.d@iias.spb.su

**Рюмин Дмитрий Александрович** — кандидат технических наук, старший научный сотрудник, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук, Санкт-Петербург, 199178, Российская Федерация, <https://orcid.org/0000-0002-7935-0569>, ryumin.d@iias.spb.su

Статья поступила в редакцию 07.05.2024  
Одобрена после рецензирования 28.05.2024  
Принята к печати 16.09.2024

## Authors

**Denis V. Ivanko** — PhD, Senior Researcher, St. Petersburg Federal Research Center of the Russian Academy of Sciences, Saint Petersburg (SPC RAS), 199178, Russian Federation, <https://orcid.org/0000-0003-0412-7765>, ivanko.d@iias.spb.su

**Dmitry A. Ryumin** — PhD, Senior Researcher, St. Petersburg Federal Research Center of the Russian Academy of Sciences, Saint Petersburg (SPC RAS), 199178, Russian Federation, <https://orcid.org/0000-0002-7935-0569>, ryumin.d@iias.spb.su

Received 07.05.2024  
Approved after reviewing 28.05.2024  
Accepted 16.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-687-698

УДК 004.3

## Обзор алгоритмов маршрутизации для сетей на кристалле

Михаил Игоревич Бондаренко<sup>1</sup>, Алексей Евгеньевич Платунов<sup>2</sup>✉

<sup>1,2</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>1</sup> ООО «Синтакор», Санкт-Петербург, 196247, Российская Федерация

<sup>1</sup> bondarenko-m-i@yandex.ru, <https://orcid.org/0009-0002-6816-4055>

<sup>2</sup> aeplatunov@ifmo.ru✉, <https://orcid.org/0000-0003-3003-3949>

### Аннотация

**Введение.** В работе исследованы алгоритмы маршрутизации для сетей на кристалле (СенК). Приведен анализ существующих алгоритмов маршрутизации, выделены их ограничения и области применения. Оценка алгоритмов проведена с учетом требований конкретных приложений и особенностей архитектур. Представлены результаты сравнения производительности рассматриваемых алгоритмов. **Метод.** Анализ и сравнение различных алгоритмов маршрутизации для СенК проведены с учетом критически важных характеристик. Основное внимание уделено таким алгоритмам маршрутизации, как детерминированный XY-алгоритм, алгоритм поворота модели, маршрутизация с учетом перегрузок, отказоустойчивая маршрутизация, маршрутизация с учетом «качества услуги», алгоритм муравьиной колонии. Показано, что выбор алгоритма маршрутизации должен основываться на специфических требованиях и условиях использования сети. Показана важность адаптации к разнообразным условиям и задачам, с которыми могут столкнуться пользователи и разработчики СенК. **Основные результаты.** С использованием данных из существующих исследований проведен анализ алгоритмов на основе нескольких ключевых показателей: задержка, пропускная способность, адаптивность, отказоустойчивость и сложность реализации. Выявлены сильные и слабые стороны каждого алгоритма в различных сценариях использования и при разной нагрузке на сеть. Показано, что выбор алгоритма маршрутизации должен опираться на конкретные требования и условия использования сети, а также на баланс между производительностью, адаптивностью, отказоустойчивостью и сложностью реализации. **Обсуждение.** Исследование вносит вклад в понимание эффективности различных алгоритмов маршрутизации в СенК. Предоставлены рекомендации для их выбора в зависимости от специфических требований приложения и архитектуры системы. Исследование способствует углублению понимания влияния алгоритмов маршрутизации на общую эффективность СенК. Предложены направления дальнейших усовершенствований в этой области. Результаты работы могут быть применены при проектировании и разработке высокопроизводительных многопроцессорных систем на кристалле, где эффективная маршрутизация данных между различными компонентами системы является ключевым фактором обеспечения высокой производительности. Подчеркнута значимость разработки отказоустойчивых алгоритмов маршрутизации, способных обеспечивать непрерывность работы системы в случае отказов отдельных компонентов или узлов. Это особенно важно для критических приложений, где непрерывность сервиса и снижение риска потери данных являются приоритетными задачами.

### Ключевые слова

интегральные схемы, многоядерные системы, сети на кристалле, шаблоны трафика, взаимоблокировка, ресурсное голодание, алгоритмы маршрутизации, детерминированные алгоритмы маршрутизации, отказоустойчивая маршрутизация, маршрутизация с учетом перегрузок, эффективность сети

**Ссылка для цитирования:** Бондаренко М.И., Платунов А.Е. Обзор алгоритмов маршрутизации для сетей на кристалле // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 687–698. doi: 10.17586/2226-1494-2024-24-5-687-698

## Overview of routing algorithms for network on chip

Mikhail I. Bondarenko<sup>1</sup>, Alexey E. Platunov<sup>2</sup>

<sup>1,2</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>1</sup> OOO "Syntacore" Saint Petersburg, 196247, Russian Federation

<sup>1,2</sup> bondarenko-m-i@yandex.ru, <https://orcid.org/0009-0002-6816-4055>

<sup>2</sup> aeplatunov@itmo.ru, <https://orcid.org/0000-0003-3003-3949>

### Abstract

This paper examines routing algorithms for networks on a chip (NoC). An analysis of existing routing algorithms is provided; their limitations and areas of application are highlighted. The algorithms were evaluated taking into account the requirements of specific applications and architecture features. The results of comparing the performance of the considered algorithms are presented. Analysis and comparison of various routing algorithms for NoC are carried out taking into account critical characteristics. The main attention is paid to such routing algorithms as the deterministic XY algorithm, the model rotation algorithm, congestion-aware routing, fault-tolerant routing, Quality of Service routing, and the ant colony algorithm. It is shown that the choice of routing algorithm should be based on the specific requirements and conditions of use of the network. The importance of adapting to a variety of conditions and tasks that NoC users and developers may encounter is shown. Based on data from existing studies, an analysis of algorithms was carried out based on several key indicators: latency, throughput, adaptability, fault tolerance and implementation complexity. The strengths and weaknesses of each algorithm are identified in various use scenarios and under different network loads. It is shown that the choice of a routing algorithm should be based on the specific requirements and conditions of use of the network, as well as on the balance between performance, adaptability, fault tolerance and implementation complexity. The study contributes to the understanding of the effectiveness of various routing algorithms in NoC, providing recommendations for their selection depending on the specific application requirements and system architecture. The study contributes to a better understanding of the impact of routing algorithms on the overall performance of NoC, suggesting directions for further improvements in this area. The results of the work can be applied in the design and development of high-performance multiprocessor systems on a chip where efficient data routing between various systems components is a key factor in ensuring high performance. The importance of developing fault-tolerant routing algorithms that can ensure the continuity of system operation in the event of failures of individual components or units is emphasized. This is especially important for mission-critical applications where service continuity and reducing the risk of data loss are top priorities.

### Keywords

integrated circuits, multicore systems, network on a chip, traffic patterns, deadlock, resource starvation, routing algorithms, deterministic routing algorithms, fault-tolerant routing, congestion-aware routing, network efficiency

**For citation:** Bondarenko M.I., Platunov A.E. Overview of routing algorithms for network on chip. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 687–698 (in Russian). doi: 10.17586/2226-1494-2024-24-5-687-698

### Введение

В настоящее время сети на кристалле (СенК) признаются ключевым компонентом в архитектуре высокопроизводительных и многопроцессорных систем на кристалле (СнК) [1]. Из-за возрастающих требований к производительности и энергоэффективности в современных вычислительных системах эффективность маршрутизации в СенК становится критически важной [2]. Однако сложность маршрутизации усугубляется разнообразием топологий сети, динамикой нагрузки и ограничениями по задержке и пропускной способности [3]. Это влечет за собой необходимость разработки алгоритмов маршрутизации, способных оптимизировать эти параметры, учитывая специфические требования приложений и архитектуры системы [4–7].

В настоящей работе рассмотрена проблема маршрутизации в СенК, ее влияние на общую производительность и энергоэффективность СнК. Выполнен анализ существующих подходов к маршрутизации в СенК, описаны их преимущества и недостатки.

### Предмет исследования

Архитектура СнК постоянно меняется, чтобы соответствовать современным тенденциям производительности и энергопотребления. Многоядерная архитектура

в настоящее время активно используется для многих СнК, и эта тенденция приобретает популярность по мере того, как все больше разработчиков выбирают этот подход. Производительность СнК в таком случае будет определяться архитектурой межсоединений. При использовании коммуникационных архитектур на основе шины снижаются временные характеристики (особенно это проявляется на этапе физического проектирования) и в целом разработка становится сложной.

Современные подходы к проектированию многоядерных СнК в качестве архитектуры межсоединений используют СенК. В такой методологии проектирования применены концепции вычислительных сетей и крупномасштабных параллельных вычислительных систем. СенК представляет собой структурированную связь между блоками и преодолевает узкие места шины с точки зрения масштабируемости.

СенК — инновационный подход к проектированию коммуникационных систем внутри интегральных схем, особенно в контексте многопроцессорных СнК. Они обеспечивают масштабируемую и эффективную методику для управления взаимосвязью между различными модулями, такими как процессоры, память и специализированные ускорители [8, 9]. Маршрутизация становится актуальной, когда число подключаемых компонентов на чипе оказывается достаточно большим, чтобы прямое их соединение стало невозможным или

незэффективным с точки зрения площади чипа и потребления энергии. При этом необходимость в реализации специальных процессов маршрутизации начинается с чипов, содержащих от 4 до 8 ядер. Современные СнК могут включать десятки или даже сотни ядер, и ожидается, что в будущем их число будет расти, учитывая тренды к увеличению производительности и масштабированию. СенК может занимать значительную часть площади чипа, особенно в сложных СнК с высокой степенью интеграции и большим числом компонентов. Это относится к реализации как коммутационных элементов и каналов связи, так и логике для управления маршрутизацией и обработкой ошибок. Удельный вес сети в общей площади чипа может изменяться и для сложных многоядерных процессоров составлять от 10 до 30 %. Временные задержки, связанные с передачей данных через СенК, важны для общей производительности СнК. Задержки могут отличаться в зависимости

от длины пути, загруженности сети и эффективности механизмов маршрутизации. В то время как современные технологии стремятся минимизировать эти задержки, они все еще играют важную роль в определении производительности высокопроизводительных вычислительных систем.

Архитектура СенК основана на принципах, используемых в компьютерных сетях и телекоммуникациях, и адаптирована для масштаба интегральных схем. Основные компоненты СенК включают вычислительные узлы, маршрутизаторы для пересылки данных между узлами и каналы связи, соединяющие маршрутизаторы. Архитектура может быть организована в различных топологиях, таких как сетка, дерево, кольцо или нестандартные топологии, специфичные для требований конкретной системы [10–12].

На рис. 1 показаны типичные архитектуры СнК на основе шинной и сетевой архитектур.

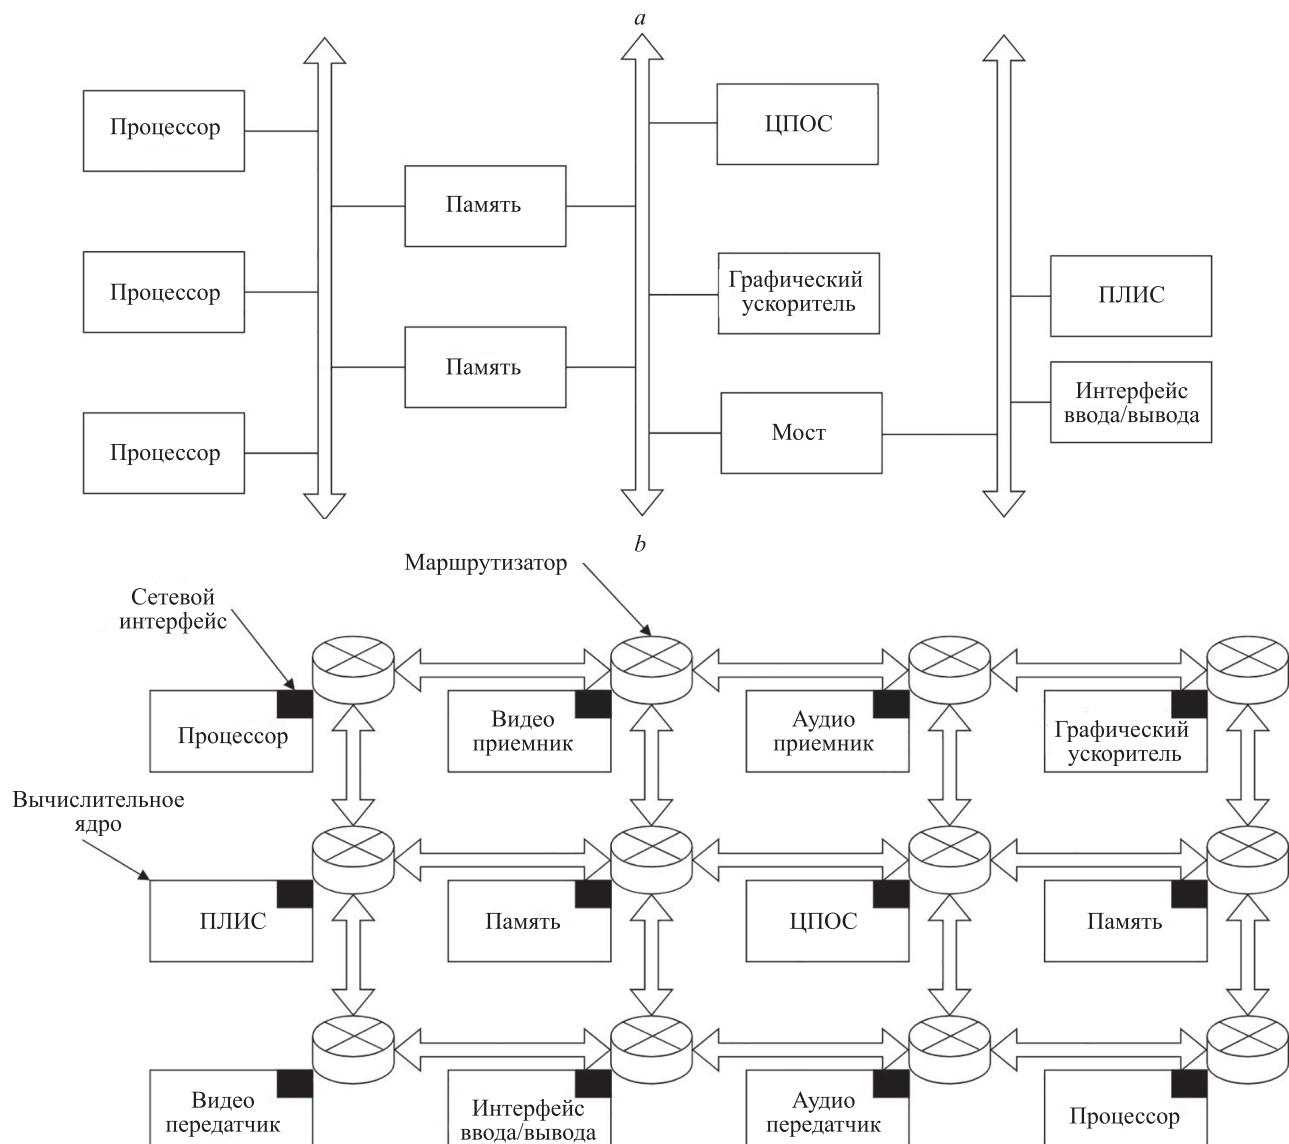


Рис. 1. Пример систем на кристалле на основе шинной (a) и сетевой архитектур (b). ЦПОС — цифровой процессор обработки сигналов, ПЛИС — программируемая логическая интегральная схема

Fig. 1. Example of systems on a chip based on bus (a) and network (b) architectures. ЦПОС — digital signal processor, ПЛИС — programmable logic integrated circuit

Сетевая архитектура имеет преимущества по сравнению с традиционными шинными СнК. Например, она обеспечивает высокую масштабируемость, позволяя эффективно увеличивать количество узлов без значительного ухудшения производительности, что является критическим для комплексных многопроцессорных СнК. В отличие от шин, где передача данных ограничена одним каналом, СенК поддерживает множество параллельных путей передачи, уменьшая задержки и увеличивая пропускную способность. Также архитектура СенК позволяет оптимизировать коммуникацию в соответствии с конкретными требованиями приложения, включая оптимизацию энергопотребления и снижение задержек.

СенК отличаются от других типов сетей рядом уникальных характеристик, обусловленных их применением в интегральных схемах. Так, СенК физически интегрированы в один кристалл полупроводника и предназначены для использования в микроэлектронике. В то время как другие типы сетей могут использовать разнообразные физические среды передачи, включая оптоволокно и радиочастоты. Кроме того, СенК предназначены для очень малых физических размеров, обычно в пределах одного кремниевого кристалла. Это принципиально отличает их от других сетей, которые могут охватывать от нескольких метров до тысяч километров. Благодаря близости компонентов СнК друг к другу и использованию специализированных протоколов и топологий, СенК могут обеспечивать очень высокую пропускную способность и минимальную задержку. Для других классов сетей обычно характерны большие задержки и ограниченная пропускная способность по причине больших расстояний и использования более универсальных протоколов. В СенК важно минимизировать энергопотребление из-за ограничений тепловыделения в интегральных схемах. В других сетях, хотя энергоэффективность также является важным фактором, ограничения по тепловыделению могут быть менее критичны. Также в СенК, как и в любой другой интегральной полупроводниковой вычислительной системе, обеспечение отказоустойчивости является критически важным вследствие отсутствия возможности внести исправления в готовый кристалл. В других типах сетей различные вышедшие из строя компоненты можно заменить исправными.

Таким образом, СенК представляют собой специализированный тип сети, оптимизированный для коммуникации внутри микроэлектронных устройств, что существенно отличает их от других сетевых технологий, предназначенных для более широкого спектра применений и условий эксплуатации.

В современном мире вычислительных систем и сетевых технологий, алгоритмы маршрутизации играют ключевую роль в обеспечении эффективности и надежности передачи данных между различными узлами в системе. Во время использования алгоритмов необходимо учитывать возможные проблемы. Например, важно равномерно распределять трафик по сети для оптимизации использования ресурсов и предотвращения узких мест, что требует сложных механизмов управления потоками и буферизации. Также мини-

мизация энергопотребления при сохранении высокой производительности маршрутизации является важной задачей, особенно в мобильных и встраиваемых системах. Различные типы сетевого трафика в СенК могут различаться в зависимости от приложения и архитектуры конкретной СнК [13, 14]. Общие модели включают в себя трафики: равномерный (каждый узел взаимодействует с любым другим узлом с равной вероятностью), локализованный (связь между определенными узлами происходит чаще [15, 16]) и трафик с всплесками (характеризуется внезапным всплеском требований к связи [17]). Существуют различные виды блокировок и недостатки ресурсов. Например, взаимоблокировка (Deadlock) возникает, когда набор пакетов блокируется навсегда, при этом каждый пакет ожидает ресурсов, которые удерживаются другими пакетами. Это создает циклическую зависимость, при которой ни один пакет не может перемещаться, что фактически останавливает связь в сети [18, 19]. Ситуация, когда пакеты постоянно меняют свое состояние или положение, но никогда не продвигаются к месту назначения, называется живая блокировка. В отличие от взаимоблокировки, пакеты не останавливаются, вместо этого они постоянно двигаются, но без продуктивных результатов [20]. Один из разновидностей недостатка ресурсов – ресурсное голодание, которое происходит, когда определенные пакеты в сети постоянно задерживаются или им отказывают в доступе к ресурсам, в то время как другие пакеты продолжают обрабатываться нормально. Это приводит к неопределенной отсрочке некоторых пакетов [21–23].

## Методы и материалы

Каждый алгоритм маршрутизации может характеризоваться несколькими показателями. В данной работе в качестве основных метрик для сравнения алгоритмов были выбраны несколько ключевых показателей — производительность (совокупность задержки и пропускной способности), адаптивность, отказоустойчивость и сложность реализации. Рассмотрим подробнее каждый из критериев сравнения (табл. 1).

В рамках настоящей работы рассмотрены различные типы статистических и динамических алгоритмов, а также дана их краткая характеристика по перечисленным критериям сравнения. Анализ основан на данных из существующих исследований, что позволяет выявить сильные и слабые стороны каждого алгоритма в различных сценариях использования и при разной нагрузке на сеть.

Дадим характеристику каждому алгоритму по перечисленным критериям.

**XY-алгоритм.** Детерминированный алгоритм, в котором пакеты сначала маршрутизируются по оси X, а затем по оси Y. Данный алгоритм обычно обеспечивает низкую задержку и высокую пропускную способность в условиях равномерного трафика благодаря своей простоте и предсказуемости. Адаптивность отсутствует, так как алгоритм не реагирует на изменения в сети, такие как перегрузка или сбои. Отказоустойчивость низкая, поскольку она не может динамически менять

Таблица 1. Метрики для сравнения алгоритмов

Table 1. Metrics for comparing algorithms

Критерий сравнения	Описание критерия
Задержка	Критически важный критерий, влияющий на производительность сети, особенно в приложениях реального времени. Исследования показывают, что алгоритмы, использующие предварительные вычисления маршрутов, как правило, обеспечивают меньшую задержку по сравнению с алгоритмами динамической маршрутизации. Однако, в условиях высокой нагрузки на сеть, динамические алгоритмы способны более эффективно адаптироваться к изменениям, что потенциально может снизить задержку за счет оптимизации путей передачи данных
Пропускная способность	Данный критерий зависит от эффективности используемых алгоритмов маршрутизации. В контексте пропускной способности алгоритмы, способные оптимизировать использование сетевых ресурсов и минимизировать коллизии, демонстрируют лучшие результаты. Выполненные исследования доказали, что алгоритмы с поддержкой множественных путей могут значительно увеличить пропускную способность за счет распределения трафика по нескольким маршрутам
Адаптивность	Адаптивность алгоритмов маршрутизации позволяет сетям эффективно реагировать на изменения в трафике и топологии сети, таким образом оптимизируя производительность сети в динамичных условиях. Алгоритмы, способные к самообучению и самонастройке, обеспечивают высокую адаптивность, что позволяет им эффективно решать задачи маршрутизации при изменяющихся условиях, включая перегрузку сети и изменение требований к задержке и пропускной способности
Отказоустойчивость	Учитывается способность алгоритма маршрутизации поддерживать непрерывность работы сети в случае отказов отдельных компонентов или узлов. Алгоритмы, обладающие высокой отказоустойчивостью, способны быстро восстанавливать работоспособность сети, перенаправляя трафик через альтернативные маршруты. Это обеспечивает непрерывность сервиса и снижает риск потери данных. Важный фактор — способность алгоритма предвидеть и компенсировать потенциальные точки отказа, а также его способность к быстрой реорганизации маршрутов в реальном времени
Сложность реализации	Сложность реализации алгоритма маршрутизации включает в себя как программную, так и аппаратную составляющие. Этот критерий сравнения оказывает значительное влияние на выбор алгоритма для конкретной вычислительной системы или сети. Алгоритмы с высокой сложностью реализации требуют более значительных ресурсов для разработки и тестирования, а также могут потребовать специализированного аппаратного обеспечения для оптимальной работы. Кроме того, более сложные алгоритмы могут представлять вызовы в плане обслуживания и масштабирования

маршрут вокруг неисправных узлов. Сложность очень низкая, что упрощает реализацию и понимание.

Работы [24, 25] представляют обзоры детерминированных алгоритмов маршрутизации, уделяя особое внимание XY-алгоритму, который является одним из наиболее простых и предсказуемых. Однако его основное ограничение — неспособность адаптироваться к перегрузкам и сбоям узлов, что делает его менее эффективным в условиях высокодинамичных и ненадежных сетей. В работах [24, 25] систематизированы знания о детерминированных алгоритмах маршрутизации, подробно рассмотрены применимость и ограничения данного алгоритма в различных сценариях использования. Для дальнейшего развития направления необходимы гибридные алгоритмы, сочетающие простоту и предсказуемость XY-алгоритма с адаптивностью к перегрузкам и отказам. Также актуально исследование динамических методов маршрутизации, способных более эффективно реагировать на изменения в условиях сети.

**Алгоритм поворота модели.** Данный алгоритм ограничивает определенные повороты, чтобы избежать тупиков. В эту категорию попадают такие варианты, как «West First», «North Last» и «Negative First». Алгоритм обеспечивает лучшую производительность, чем XY-алгоритм, благодаря частичной адаптивности,

что помогает избегать определенных перегрузок сети. Отметим, что алгоритм поворота модели не является полностью динамичным. Отказоустойчивость у него лучше, чем у XY-алгоритма, но не так надежна, как у полностью адаптивных или отказоустойчивых алгоритмов. Сложность выше, чем у XY-алгоритма, но управляема.

Работы [26, 27] оказали большое влияние на развитие алгоритмов маршрутизации для СенК, предлагая адаптивные модели маршрутизации для повышения производительности и надежности сети. Алгоритм поворота модели предлагает улучшенную адаптивность за счет возможности обхода перегруженных и неисправных узлов, что улучшает общую производительность сети. Повышается отказоустойчивость сети, позволяя динамически менять маршруты и обеспечивать непрерывность работы при сбоях. Увеличение пропускной способности и снижение задержек достигается за счет оптимизации маршрутов и динамического распределения трафика. Увеличение сложности алгоритмов требует значительных вычислительных ресурсов, что может ограничить их применение в масштабируемых системах. Вопросы энергоэффективности остаются недостаточно исследованными, что важно для современных многопроцессорных систем. Необходимы дополнительные эксперименты и симуляции для под-

тврждения эффективности предложенных решений в реальных условиях. В работах [26, 27] предложены перспективные решения для маршрутизации в СенК, однако они требуют дальнейших исследований для уменьшения сложности реализации и улучшения энергоэффективности. Эти аспекты могут стать объектом будущих исследований, направленных на оптимизацию производительности и надежности СенК.

**Маршрутизация с учетом перегрузок.** Алгоритм специально разработан для обнаружения и предотвращения перегруженных областей в сети. Решения по маршрутизации принимаются на основе текущей нагрузки трафика с целью его балансировки и уменьшения узких мест [28, 29]. Уменьшение задержки и повышение пропускной способности достигается за счет исключения перегруженных маршрутов. Данная маршрутизация имеет умеренную отказоустойчивость, так как в первую очередь ориентирована на перегрузку. В зависимости от механизма обнаружения и управления перегрузками сложность варьируется от средней до высокой.

В работе [28] рассмотрен алгоритм, направленный на уменьшение задержек и повышение пропускной способности. Однако его тестирование проводилось только на синтетических нагрузках, что вызывает сомнения в его эффективности в реальных условиях. Кроме того, не рассмотрены вопросы масштабируемости алгоритма при увеличении размеров сети. Работа [29] описывает гибридный алгоритм маршрутизации, сочетающий детерминированные и аддитивные методы для повышения устойчивости сети к перегрузкам. Несмотря на то, что экспериментальные данные подтверждают его эффективность, в [29] недостаточно освещены вычислительные затраты, связанные с реализацией гибридного подхода. Это требует дальнейшего исследования для оценки влияния на производительность и оптимизации алгоритма. Таким образом, работы [28, 29] имеют ценные идеи, но требуют дополнительной проверки и оптимизации для практического применения в больших и сложных СенК.

**Отказоустойчивая маршрутизация.** При использовании данного алгоритма основное внимание уделяется обеспечению непрерывной работы при наличии неисправностей в сети. Алгоритм динамически идентифицирует и обходит неисправные компоненты. Может наблюдаться увеличение задержки из-за обхода неисправных мест, он показывает высокую эффективность при адаптации к сбоям в сети, в меньшей степени при перегрузках. Высокая отказоустойчивость сети подтверждается. Сложность изменяется, но обычно увеличивается из-за необходимости обнаружения и устранения неисправностей.

В работах [30, 31] предложено повышение отказоустойчивости в СенК. Описан динамичный алгоритм, эффективно обходящий неисправные участки сети, обеспечивая непрерывность сервиса. Также проведен формальный анализ подобного алгоритма, подтверждая его корректность и надежность. Основным преимуществом динамического алгоритма является высокая адаптивность к отказам и возможность поддержания работоспособности сети в критических условиях. Тем

не менее, такой алгоритм может столкнуться с проблемами, связанными с повышенной задержкой при обходе неисправностей и высокой сложностью реализации, что требует значительных вычислительных ресурсов. Таким образом, данные исследования содержат полезные сведения об отказоустойчивой маршрутизации в СенК, но требуют дальнейших исследований для оптимизации алгоритмов и снижения их сложности.

**Маршрутизация с учетом качества обслуживания (Quality of Service, QoS).** В результате работы данного алгоритма выполняется обработка различных типов трафика, гарантируя, что пакеты с высоким приоритетом получат более быстрые и надежные маршруты. Алгоритм может оптимизировать задержку или пропускную способность на основе приоритетов пакетов и адаптируется к условиям сети на основе требований QoS. Отказоустойчивость варьируется, так как не является основной задачей этого алгоритма. Сложность высокая, поскольку требует сложных механизмов для категоризации и определения приоритетности трафика.

Работы [32, 33] посвящены улучшению QoS в СенК через разработку специализированных алгоритмов маршрутизации. Предложена методика управления потоками QoS, которая способна адаптироваться к различным условиям сети и обеспечивать гарантии по задержке и пропускной способности. Однако работа [32] не предоставляет достаточно данных о производительности в условиях высоких нагрузок и не рассматривает аспекты отказоустойчивости. Кроме того, неясна масштабируемость предложенного подхода при увеличении числа узлов. Также рассмотрен алгоритм, основанный на поведении пчел, для аддитивной маршрутизации трафика с учетом QoS. Этот инновационный подход требует значительных вычислительных ресурсов и сложен в реализации. В [33] отсутствует сравнительный анализ с существующими алгоритмами, а также детальные данные об отказоустойчивости. Требуются дальнейшие исследования по следующим направлениям — анализ производительности в условиях высоких нагрузок, оценка отказоустойчивости и масштабируемости предложенных методов, сравнение с существующими алгоритмами для объективной оценки эффективности.

**Алгоритм муравьиной колонии.** Алгоритм основан на поведении муравьев при поиске путей к источникам пищи. Он использует искусственных муравьев для исследования сети и прокладки феромонных следов (т. е. присвоение весов). Решения о маршрутизации основаны на этих уровнях феромонов, которые отражают полезность путей. Задержка и пропускная способность могут быть эффективными, но изначально хуже на этапе обучения. Адаптивность алгоритма высокая — происходит постоянная оптимизация путей в зависимости от условий сети. Отказоустойчивость хорошая, благодаря своей динамичности и способности находить новые пути. Сложность довольно высокая, из-за затрат на управление виртуальными муравьями и следами феромонов.

В [34, 35] рассмотрены современные подходы к маршрутизации СенК, включая алгоритм муравьиной колонии. Работа [34] анализирует производительность

и адаптивность — алгоритм демонстрирует хорошие показатели по задержке и пропускной способности, особенно после начального этапа обучения. Он эффективно адаптируется к изменениям в сети, что позволяет ему быстро оптимизировать маршруты. Способность алгоритма находить новые пути обеспечивает высокую отказоустойчивость системы. Вместе с тем у данного алгоритма существуют нерешенные проблемы. Например, высокие затраты на управление виртуальными муравьями и следами феромонов могут вызвать сложности при внедрении. Также на этапе обучения алгоритм может демонстрировать повышенную задержку, что критично для систем с высокими требованиями к начальной производительности. Работа [35] включает детальный анализ производительности, адаптивности, отказоустойчивости и сложности реализации различных алгоритмов маршрутизации. Это дает всестороннее представление о текущем состоянии исследований и ценные рекомендации для разработчиков. Недостаток примеров внедрения описанных алгоритмов в реальных системах снижает их прикладную ценность. Работа охватывает широкий спектр алгоритмов, но глубина анализа каждого из них могла бы быть более подробной.

Чтобы проиллюстрировать отличительные особенности в алгоритмах маршрутизации между СенК и другими категориями сетей, рассмотрим пример алгоритма маршрутизации *XY*, используемого в СенК, и сравним его с дистанционно-векторным алгоритмом маршрутизации, обычно применяемого в более крупных компьютерных сетях.

Приведем особенности *XY*-алгоритма СенК, позволяющие улучшить *XY*-маршрутизацию. Сетчатая топология СенК позволяет *XY*-маршрутизации быть высокоеффективной и предсказуемой, обеспечивая минимальное отклонение от маршрута и оптимизируя задержку. Избегая сложных вычислений пути, *XY*-алгоритм минимизирует задержку маршрутизации и поддерживает высокую пропускную способность, необходимую для внутристековых коммуникаций. Простота *XY*-алгоритма делает его ресурсосберегающим, требующим меньше энергии и площади, чем более сложные алгоритмы, что имеет решающее значение в условиях ограниченных возможностей чипа.

Маршрутизация по дистанционно-векторному алгоритму используется в крупномасштабных сетях, таких как Интернет. Он предполагает, что маршрутизаторы совместно используют свои таблицы маршрутизации с ближайшими соседями и каждый маршрутизатор обновляет таблицу маршрутизации на основе полученной информации, чтобы определить кратчайший путь к каждому пункту назначения. Среди различий для маршрутизации по дистанционно-векторному алгоритму можно выделить адаптивность к динамическим топологиям — в отличие от *XY*-маршрутизации. Данный алгоритм может адаптироваться к изменениям в топологии сети, таким как сбои соединения и добавление новых узлов, что делает его подходящим для больших и динамичных сетей. Также пути, определяемые дистанционно-векторным алгоритмом, могут изменяться с течением времени по мере изменения топологии сети, в отличие от предопределенной топо-

логии в СенК. Необходимость периодического обмена таблицами маршрутизации и вычисления путей может привести к дополнительной задержке и потреблению большей полосы пропускания (полосу пропускания — объем данных, который может быть передан через сеть за определенный период времени). В контексте СенК, полоса пропускания зависит от нескольких ключевых факторов: архитектура сети, трафик и выбранный алгоритм маршрутизации.

Использование СенК может привнести улучшения алгоритмов, например, оптимизация для конкретной топологии — известная топология СенК позволяет разрабатывать алгоритмы маршрутизации, которые непосредственно адаптированы к архитектуре сети, повышая эффективность и предсказуемость. Также алгоритмы маршрутизации СенК могут быть оптимизированы наряду с общей архитектурой чипа, что позволяет использовать целостный подход, учитывающий как вычислительные, так и коммуникационные требования, оптимизируя энергопотребление, задержку и пропускную способность. Существующие возможности настройки алгоритмов маршрутизации под конкретные требования приложений или схемы трафика в СенК могут значительно улучшить показатели производительности, в отличие от более общих подходов, требуемых в крупных и гетерогенных сетях.

Таким образом, рассмотренный пример показал, как уникальные характеристики СенК позволяют разрабатывать высокоеффективные и оптимизированные алгоритмы маршрутизации, адаптированные к конкретным требованиям СнК.

## Результаты и обсуждение

В рамках работы был выполнен анализ, по результатам которого можно дать оценку эффективности алгоритмов и показать в каких обстоятельствах каждый алгоритм проявляет себя лучше всего. Алгоритмы оценены по трехбалльной шкале (один закрашенный квадратик соответствует 1 баллу), результаты сведены в табл. 2.

Из табл. 2 видно, что для простых и предсказуемых СенК *XY*-маршрутизация эффективна и достаточна [36, 37]. В сценариях с умеренной изменчивостью и перегруженностью маршрутизация с использованием модели поворота является сбалансированным выбором [38, 39]. При работе с изменяющейся нагрузкой трафика оптимальным является маршрутизация с учетом перегрузки [40]. В системах, подверженных сбоям, отказоустойчивая маршрутизация имеет решающее значение для надежности [41, 42]. Для разнообразных требований к трафику QoS маршрутизация предлагает индивидуальные решения [43, 44]. В высокодинамичных и сложных системах алгоритм муравьиной колонии предлагает инновационную адаптивность, основанную на обучении [45].

На представленных графиках (рис. 2) показана ожидаемая зависимость задержки и пропускной способности для различных алгоритмов маршрутизации при разных уровнях нагрузки на сеть, которую планируется подтвердить в дальнейшем после получения результатов симуляции.

Таблица 2. Результаты сравнения алгоритмов

Table 2. Algorithm comparison results

Критерий сравнения	Алгоритм					
	XY-алгоритм	Алгоритм поворота модели	Маршрутизация с учетом перегрузок	Отказоустойчивая маршрутизация	Маршрутизация с учетом QoS	Алгоритм муравьиной колонии
Задержка и пропускная способность						
Адаптивность						
Отказоустойчивость						
Сложность						

На графике зависимости задержки от нагрузки на сеть (рис. 2, а) видно, что XY-алгоритм показывает стабильное увеличение задержки с ростом нагрузки, но относительно низкое по сравнению с другими алгоритмами при низкой нагрузке. Алгоритм поворота модели демонстрирует улучшенную производительность по сравнению с XY-алгоритмом, особенно при средних уровнях нагрузки. Маршрутизация с учетом перегрузок имеет минимальную задержку при низкой и средней нагрузках, но начинает увеличиваться при высокой нагрузке. Отказоустойчивая маршрутизация показывает изначально высокую задержку, что объясняется устойчивостью к сбоям. У маршрутизации с учетом QoS задержка растет с увеличением нагрузки, показывая хорошую производительность при средних уровнях нагрузки. Алгоритм муравьиной колонии демонстрирует минимальную задержку при низкой и средней нагрузках, но увеличивается при высокой нагрузке, отражая время на обучение и адаптацию маршрутов.

На графике пропускной способности от нагрузки на сеть (рис. 2, б) XY-алгоритм показывает высокую пропускную способность, достигая почти максимальных

значений при высокой нагрузке. Алгоритм поворота модели близок по производительности к XY-алгоритму, с небольшими улучшениями при высокой нагрузке. Маршрутизация с учетом перегрузок достигает наивысшей пропускной способности, особенно при средней и высокой нагрузках, эффективно распределяя трафик. Отказоустойчивая маршрутизация демонстрирует более низкую пропускную способность по сравнению с другими алгоритмами, что компенсируется отказоустойчивостью. Маршрутизация с учетом QoS показывает высокую пропускную способность, оптимизированную для приоритизации трафика. Алгоритм муравьиной колонии близок к максимальной пропускной способности при всех уровнях нагрузки, благодаря динамическому выбору маршрутов.

Полученные графики зависимостей (рис. 2) иллюстрируют то, как различные алгоритмы маршрутизации справляются с увеличением нагрузки на сеть, показывая их сильные и слабые стороны в условиях различных сценариев.

На следующем этапе работы предлагается разработка и верификация модели СенК. Основное внимание

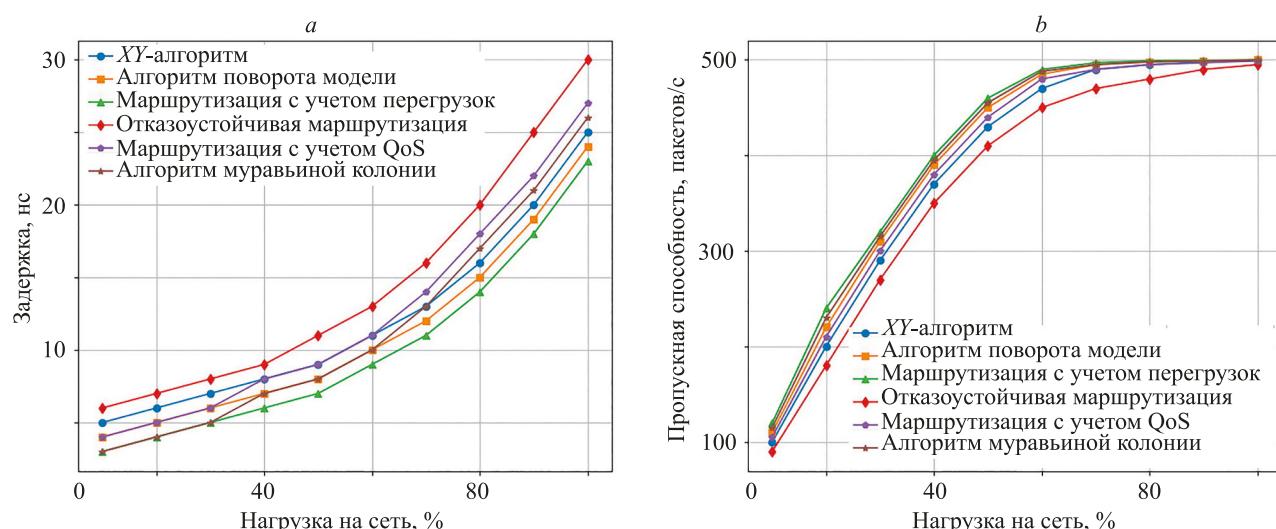


Рис. 2. Зависимости задержки (а) и пропускной способности (б) от нагрузки на сеть

Fig. 2. Graphs of latency and throughput vs. the network load

будет уделено созданию точной и масштабируемой модели, которая позволит эмулировать различные архитектурные и операционные сценарии в СенК.

Среди ожидаемых результатов выделим: настраиваемую модель СенК (способную адаптироваться к различным архитектурным требованиям); проведение «чистого» и полунатурного моделирования (с использованием программного обеспечения и программируемой логической интегральной схемы (ПЛИС) соответственно); разработанный набор тестов для валидации модели (включая проверку производительности, пропускной способности и задержек); сравнение полученной модели с существующими (что позволит оценить ее преимущества).

Необходимость экспериментальных исследований, в частности «чистого» моделирования, можно объяснить использованием программных средств для моделирования работы СенК без физического воплощения элементов. Данный метод позволит снизить затраты и время на эксперименты. Быстро модифицируя параметры системы, можно протестировать широкий спектр сценариев и архитектурных решений и оценить их влияние на общую производительность. Применение полунатурного моделирования, необходимо так как применение ПЛИС позволяет создавать более реалистичные модели работы СенК. Такой подход поможет оценить реальные физические ограничения и потенциальные неполадки, которые могут не быть очевидны при «чистом» моделировании.

Предложенное направление дальнейшей работы позволит не только подтвердить теоретические разработки на практике, но и значительно упростить процесс тестирования и внедрения новых архитектурных решений для СенК. Это также способствует более глубокому пониманию ограничений и возможностей СенК в условиях реальной эксплуатации.

Развитие новых стратегий маршрутизации, способных адаптироваться к изменяющимся условиям и требованиям, будет играть ключевую роль в обеспечении будущего развития интегральных схем и многопроцессорных систем на кристалле [46–48]. Это особенно важно для приложений, требующих высокой производи-

тельности, надежности и энергоэффективности, таких как большие многопроцессорные системы, интеллектуальные транспортные системы и распределенные вычислительные сети.

## Заключение

Выполнен анализ существующих алгоритмов маршрутизации в сетях на кристалле. Показано, что эффективность маршрутизации в сетях на кристалле варьируется в зависимости от выбора между основными критериями: производительностью, адаптивностью, отказоустойчивостью и сложностью реализации. Так, например, наиболее простые алгоритмы маршрутизации, хотя и не представляют сложности в реализации, ограничены в адаптивности и отказоустойчивости, в то время как более сложные алгоритмы, предлагают значительные преимущества в плане адаптивности и отказоустойчивости, но требуют более сложной реализации и управления. Определение оптимального алгоритма маршрутизации требует глубокого понимания как специфики архитектуры сетей на кристалле, так и характеристик трафика приложения. В будущих исследованиях следует сосредоточить усилия на разработке и оптимизации гибридных алгоритмов маршрутизации, которые могли бы сочетать в себе преимущества детерминированных и адаптивных методов, обеспечивая таким образом высокую производительность и отказоустойчивость при минимальной сложности реализации.

Проведенное исследование можно взять как основу для дальнейшей работы в этой области — разработки собственного алгоритма маршрутизации для сетей на кристалле, включающего в себя разработку прототипа на программируемой логической интегральной схеме. Кроме того, значительный интерес представляет разработка методик точного моделирования и оценки производительности различных алгоритмов в условиях динамически изменяющегося трафика и топологии сети, что позволит еще более эффективно подбирать алгоритмы маршрутизации под конкретные задачи и условия эксплуатации.

## Литература

1. Benini L., De Micheli G. Networks on chip: a new paradigm for systems on chip design // Proc. of the Design, Automation and Test in Europe Conference and Exhibition. 2002. P. 418–419. <https://doi.org/10.1109/DATe.2002.998307>
2. Bjerregaard T., Mahadevan S. A survey of research and practices of Network-on-chip // ACM Computing Surveys. 2006. V. 38. N 1. P. 1. <https://doi.org/10.1145/1132952.1132953>
3. Dielissen J., Goossens K., Rijpkema E. Concepts and Implementation of the Philips Network-on-Chip, 2003 [Электронный ресурс]. URL: <https://www.es.ele.tue.nl/~kgoossens/2003-ipsoc.pdf> (дата обращения: 20.02.2024).
4. Bertozi D., Benini L., De Micheli G. Energy-efficient network-on-chip design // Ultra Low-Power Electronics and Design, 2004. P. 214–232. [https://doi.org/10.1007/1-4020-8076-X\\_12](https://doi.org/10.1007/1-4020-8076-X_12)
5. Mazumdar S., Scionti A., Portero A., Martinović J., Terzo O. A scalable and low-power FPGA-aware network-on-chip architecture // Advances in Intelligent Systems and Computing. 2018. V. 611. P. 407–420. [https://doi.org/10.1007/978-3-319-61566-0\\_37](https://doi.org/10.1007/978-3-319-61566-0_37)

## References

1. Benini L., De Micheli G. Networks on chip: a new paradigm for systems on chip design. *Proc. of the Design, Automation and Test in Europe Conference and Exhibition*, 2002, pp. 418–419. <https://doi.org/10.1109/DATe.2002.998307>
2. Bjerregaard T., Mahadevan S. A survey of research and practices of Network-on-chip. *ACM Computing Surveys*, 2006, vol. 38, no. 1, pp. 1. <https://doi.org/10.1145/1132952.1132953>
3. Dielissen J., Goossens K., Rijpkema E. *Concepts and Implementation of the Philips Network-on-Chip*, 2003. Available at: <https://www.es.ele.tue.nl/~kgoossens/2003-ipsoc.pdf> (accessed: 20.02.2024).
4. Bertozi D., Benini L., De Micheli G. Energy-efficient network-on-chip design. *Ultra Low-Power Electronics and Design*, 2004, pp. 214–232. [https://doi.org/10.1007/1-4020-8076-X\\_12](https://doi.org/10.1007/1-4020-8076-X_12)
5. Mazumdar S., Scionti A., Portero A., Martinović J., Terzo O. A scalable and low-power FPGA-aware network-on-chip architecture. *Advances in Intelligent Systems and Computing*, 2018, vol. 611, pp. 407–420. [https://doi.org/10.1007/978-3-319-61566-0\\_37](https://doi.org/10.1007/978-3-319-61566-0_37)

6. Palesi M., Daneshthalab M. Routing Algorithms in Networks-on-Chip. Springer, 2014. 410 p. <https://doi.org/10.1007/978-1-4614-8274-1>
7. Khan K., Pasricha S. A reinforcement learning framework with region-awareness and shared path experience for efficient routing in networks-on-chip // IEEE Design & Test. 2023. V. 40. N 6. P. 76–85. <https://doi.org/10.1109/MDAT.2023.3306719>
8. Dally W.J., Towles B. Route packets, not wires: On-chip interconnection networks // Proc. of the 38<sup>th</sup> Design Automation Conference. 2001. P. 684–689. <https://doi.org/10.1109/dac.2001.935594>
9. Murali S., De Micheli G. Bandwidth-constrained mapping of cores onto NoC architectures // Proceedings Design, Automation and Test in Europe Conference and Exhibition. V. 2. 2004. P. 896–901. <https://doi.org/10.1109/DATE.2004.1269002>
10. Ma S., Wang Z., Enright Jerger N., Shen L., Xiao N. Novel flow control for fully adaptive routing in cache-coherent NoCs // IEEE Transactions on Parallel and Distributed Systems. 2014. V. 25. N 9. P. 2397–2407. <https://doi.org/10.1109/TPDS.2013.166>
11. Nicopoulos C.A., Park D., Kim J., Vijaykrishnan N., Yousif M.S., Das C.R. ViChaR: A dynamic virtual channel regulator for network-on-chip routers // Proc. of the 39<sup>th</sup> Annual IEEE/ACM International Symposium on Microarchitecture (MICRO'06). 2006. P. 333–346. <https://doi.org/10.1109/MICRO.2006.50>
12. Owens J.D., Dally W.J., Ho R., Jayasimha D.N., Keckler S.W., Peh L.-S. Research challenges for on-chip interconnection networks // IEEE Micro. 2007. V. 27. N 5. P. 96–108. <https://doi.org/10.1109/MM.2007.4378787>
13. Mak T., Cheung P.Y.K., Lam K.-P., Luk W. Adaptive routing in network-on-chips using a dynamic-programming network // IEEE Transactions on Industrial Electronics. 2011. V. 58. N 8. P. 3701–3716. <https://doi.org/10.1109/TIE.2010.2081953>
14. Paliwal K.K., Gaur M.S., Laxmi V., Janyani V. Performance analysis of guaranteed throughput and best effort traffic in network-on-chip under different traffic scenario // Proc. of the International Conference on Future Networks. 2009. P. 74–78. <https://doi.org/10.1109/ICFN.2009.45>
15. Tedesco L., Mello A., Garibotti D., Calazans N., Moraes F. Traffic generation and performance evaluation for mesh-based NoCs // Proc. of the 18<sup>th</sup> Symposium on Integrated Circuits and Systems Design. 2005. P. 184–189. <https://doi.org/10.1109/SBCCI.2005.4286854>
16. Soteriou V., Wang H., Peh L. A statistical traffic model for on-chip interconnection networks // Proc. of the 14<sup>th</sup> IEEE International Symposium on Modeling, Analysis, and Simulation. 2006. P. 104–116. <https://doi.org/10.1109/MASCOTS.2006.9>
17. Velayudham S., Rajagopal S., Kathirvel S., Alhadidi B. An overview of multicast routing algorithms in network on chip // Learning and Analytics in Intelligent Systems. 2021. V. 21. P. 163–178. [https://doi.org/10.1007/978-3-030-65407-8\\_14](https://doi.org/10.1007/978-3-030-65407-8_14)
18. Xiang D., Yu Z., Wu J. Deadlock-free fully adaptive routing in irregular networks without virtual channels // Proc. of the 12<sup>th</sup> IEEE International Conference on Trust, Security and Privacy in Computing and Communications. 2013. P. 983–990. <https://doi.org/10.1109/TrustCom.2013.120>
19. Palesi M., Holmsmark R., Kumar S., Catania V. A methodology for design of application specific deadlock-free routing algorithms for NoC systems // Proc. of the 4<sup>th</sup> International Conference on Hardware/Software Codesign and System Synthesis. 2006. P. 142–147. <https://doi.org/10.1145/1176254.1176289>
20. Taheri E., Pasricha S., Nikdast M. DeFT: A Deadlock-free and fault-tolerant routing algorithm for 2.5D chiplet networks // Proc. of the Design, Automation & Test in Europe Conference & Exhibition (DATE). 2022. P. 1047–1052. <https://doi.org/10.23919/DATE54114.2022.9774617>
21. Valinataj M., Mohammadi S., Plosila J., Liljeberg P. A fault-tolerant and congestion-aware routing algorithm for Networks-on-Chip // Proc. of the 13<sup>th</sup> IEEE Symposium on Design and Diagnostics of Electronic Circuits and Systems. 2010. P. 139–144. <https://doi.org/10.1109/DDECS.2010.5491798>
22. Patooghy A., Tabkhi H., Miremadi S.G. An efficient method to reliable data transmission in Network-on-Chips // Proc. of the 13<sup>th</sup> Euromicro Conference on Digital System Design: Architectures, Methods and Tools. 2010. P. 467–474. <https://doi.org/10.1109/DSD.2010.23>
23. Lysne O., Montanana J.M., Flieh J., Duato J., Pinkston T.M., Skeie T. An efficient and deadlock-free network reconfiguration protocol // IEEE Transactions on Computers. 2008. V. 57. N 6. P. 762–779. <https://doi.org/10.1109/TC.2008.31>
6. Palesi M., Daneshthalab M. *Routing Algorithms in Networks-on-Chip*. Springer, 2014. 410 p. <https://doi.org/10.1007/978-1-4614-8274-1>
7. Khan K., Pasricha S. A reinforcement learning framework with region-awareness and shared path experience for efficient routing in networks-on-chip // IEEE Design & Test. 2023, vol. 40, no. 6, pp. 76–85. <https://doi.org/10.1109/MDAT.2023.3306719>
8. Dally W.J., Towles B. Route packets, not wires: On-chip interconnection networks. *Proc. of the 38<sup>th</sup> Design Automation Conference*, 2001, pp. 684–689. <https://doi.org/10.1109/dac.2001.935594>
9. Murali S., De Micheli G. Bandwidth-constrained mapping of cores onto NoC architectures. *Proceedings Design, Automation and Test in Europe Conference and Exhibition*. V. 2, 2004, pp. 896–901. <https://doi.org/10.1109/DATE.2004.1269002>
10. Ma S., Wang Z., Enright Jerger N., Shen L., Xiao N. Novel flow control for fully adaptive routing in cache-coherent NoCs. *IEEE Transactions on Parallel and Distributed Systems*, 2014, vol. 25, no. 9, pp. 2397–2407. <https://doi.org/10.1109/TPDS.2013.166>
11. Nicopoulos C.A., Park D., Kim J., Vijaykrishnan N., Yousif M.S., Das C.R. ViChaR: A dynamic virtual channel regulator for network-on-chip routers. *Proc. of the 39<sup>th</sup> Annual IEEE/ACM International Symposium on Microarchitecture (MICRO'06)*, 2006, pp. 333–346. <https://doi.org/10.1109/MICRO.2006.50>
12. Owens J.D., Dally W.J., Ho R., Jayasimha D.N., Keckler S.W., Peh L.-S. Research challenges for on-chip interconnection networks. *IEEE Micro*, 2007, vol. 27, no. 5, pp. 96–108. <https://doi.org/10.1109/MM.2007.4378787>
13. Mak T., Cheung P.Y.K., Lam K.-P., Luk W. Adaptive routing in network-on-chips using a dynamic-programming network. *IEEE Transactions on Industrial Electronics*, 2011, vol. 58, no. 8, pp. 3701–3716. <https://doi.org/10.1109/TIE.2010.2081953>
14. Paliwal K.K., Gaur M.S., Laxmi V., Janyani V. Performance analysis of guaranteed throughput and best effort traffic in network-on-chip under different traffic scenario. *Proc. of the International Conference on Future Networks*, 2009, pp. 74–78. <https://doi.org/10.1109/ICFN.2009.45>
15. Tedesco L., Mello A., Garibotti D., Calazans N., Moraes F. Traffic generation and performance evaluation for mesh-based NoCs. *Proc. of the 18<sup>th</sup> Symposium on Integrated Circuits and Systems Design*, 2005, pp. 184–189. <https://doi.org/10.1109/SBCCI.2005.4286854>
16. Soteriou V., Wang H., Peh L. A statistical traffic model for on-chip interconnection networks. *Proc. of the 14<sup>th</sup> IEEE International Symposium on Modeling, Analysis, and Simulation*, 2006, pp. 104–116. <https://doi.org/10.1109/MASCOTS.2006.9>
17. Velayudham S., Rajagopal S., Kathirvel S., Alhadidi B. An overview of multicast routing algorithms in network on chip. *Learning and Analytics in Intelligent Systems*, 2021, vol. 21, pp. 163–178. [https://doi.org/10.1007/978-3-030-65407-8\\_14](https://doi.org/10.1007/978-3-030-65407-8_14)
18. Xiang D., Yu Z., Wu J. Deadlock-free fully adaptive routing in irregular networks without virtual channels. *Proc. of the 12<sup>th</sup> IEEE International Conference on Trust, Security and Privacy in Computing and Communications*, 2013, pp. 983–990. <https://doi.org/10.1109/TrustCom.2013.120>
19. Palesi M., Holmsmark R., Kumar S., Catania V. A methodology for design of application specific deadlock-free routing algorithms for NoC systems. *Proc. of the 4<sup>th</sup> International Conference on Hardware/Software Codesign and System Synthesis*, 2006, pp. 142–147. <https://doi.org/10.1145/1176254.1176289>
20. Taheri E., Pasricha S., Nikdast M. DeFT: A Deadlock-free and fault-tolerant routing algorithm for 2.5D chiplet networks. *Proc. of the Design, Automation & Test in Europe Conference & Exhibition (DATE)*, 2022, pp. 1047–1052. <https://doi.org/10.23919/DATE54114.2022.9774617>
21. Valinataj M., Mohammadi S., Plosila J., Liljeberg P. A fault-tolerant and congestion-aware routing algorithm for Networks-on-Chip. *Proc. of the 13<sup>th</sup> IEEE Symposium on Design and Diagnostics of Electronic Circuits and Systems*, 2010, pp. 139–144. <https://doi.org/10.1109/DDECS.2010.5491798>
22. Patooghy A., Tabkhi H., Miremadi S.G. An efficient method to reliable data transmission in Network-on-Chips. *Proc. of the 13<sup>th</sup> Euromicro Conference on Digital System Design: Architectures, Methods and Tools*, 2010, pp. 467–474. <https://doi.org/10.1109/DSD.2010.23>
23. Lysne O., Montanana J.M., Flieh J., Duato J., Pinkston T.M., Skeie T. An efficient and deadlock-free network reconfiguration protocol. *IEEE Transactions on Computers*, 2008, vol. 57, no. 6, pp. 762–779. <https://doi.org/10.1109/TC.2008.31>

24. Adamu G., Chejara P., Garko A. Review of deterministic routing algorithm for Network-on-Chip // International Journal of Advance Research in Science and Engineering. 2015. V. 4. Spec. Issue 1. P. 123–128.
25. Mahendra C., Gaikwad M., Patrikar R. Review of XY routing algorithm for network-on-chip architecture // International Journal of Computer and Communication Technology. 2016. V. 43. P. 20–23. <https://doi.org/10.47893/IJCCT.2016.1384>
26. Kumar M., Laxmi V., Gaur M.S., Daneshtalab M., Zwolinski M. A novel non-minimal turn model for highly adaptive routing in 2D NoCs // Proc. of the 22<sup>nd</sup> International Conference on Very Large Scale Integration (VLSI-SoC). 2014. P. 1–6. <https://doi.org/10.1109/VLSI-SoC.2014.7004192>
27. Brown J.W. Adaptive Network on Chip Routing using the Turn Model: Master's Theses and Capstones. 2013 [Электронный ресурс]. URL: <https://scholars.unh.edu/thesis/779> (дата обращения: 20.02.2024)
28. Ahmad K., Sethi M.A.J., Ullah R., Ahmed I., Ullah A., Jan N., Karami G.M. Congestion-aware routing algorithm for NoC using data packets // Wireless Communications and Mobile Computing. 2021. V. 2921. <https://doi.org/10.1155/2021/8588646>
29. Ponnan S., Kumar T.A., Hemakumar V.S., Natarajan S., Shah M.A. Congestion aware low power on chip protocols with network on chip with cloud security // Journal of Cloud Computing. 2022. V. 11. N. 1. P. 41. <https://doi.org/10.1186/s13677-022-00307-4>
30. Akbar R., Etedalpour A.A., Safaei F. An efficient fault-tolerant routing algorithm in NoCs to tolerate permanent faults // The Journal of Supercomputing. 2016. V. 72. N. 12. P. 4629–4650. <https://doi.org/10.1007/s11227-016-1749-0>
31. Zhang Z., Serwe W., Wu J., Yoneda T., Zheng H., Myers C. Formal analysis of a fault-tolerant routing algorithm for a Network-on-Chip // Lecture Notes in Computer Science. 2014. V. 8718. P. 48–62. [https://doi.org/10.1007/978-3-319-10702-8\\_4](https://doi.org/10.1007/978-3-319-10702-8_4)
32. Carara E., Calazans N., Moraes F. Managing QoS flows at task level in NoC-based MPSoCs // Proc. of the 17<sup>th</sup> IFIP International Conference on Very Large Scale Integration. (VLSI-SoC). 2009. P. 133–138. <https://doi.org/10.1109/VLSISOC.2009.6041343>
33. Xie P., Gu H. Intelligent bees for QoS routing in Networks-on-Chip // Proc. of the Second Pacific-Asia Conference on Circuits, Communications and System. 2010. P. 311–314. <https://doi.org/10.1109/PACCS.2010.5626974>
34. Nedjah N., de Macedo Mourelle L. Routing in Network-on-Chips using ant colony optimization // Studies in Computational Intelligence. 2014. V. 529. P. 173–198. [https://doi.org/10.1007/978-3-319-03110-1\\_11](https://doi.org/10.1007/978-3-319-03110-1_11)
35. Nedjah N., Silva Junior L., De Macedo Mourelle L. Congestion-aware an colony based routing algorithms for efficient application execution on Network-on-Chip platform // Expert Systems with Applications. 2013. V. 40. N. 16. P. 6661–6673. <https://doi.org/10.1016/j.eswa.2013.06.005>
36. Ahmad K., Sethi M.A.J. Review of Network on Chip routing algorithms // EAI Endorsed Transactions on Context-aware Systems and Applications. 2020. V. 7. N. 2. P. e5. <https://doi.org/10.4108/eai.23-12-2020.167793>
37. Xu Y., Zhou J., Liu S. Research and analysis of routing algorithms for NoC // Proc. of the 3<sup>rd</sup> International Conference on Computer Research and Development. 2011. P. 98–102. <https://doi.org/10.1109/ICCRD.2011.5764092>
38. Uma R., Sarojadevi H., Sanju V. Network-On-Chip (NoC) - routing techniques: a study and analysis // Proc. of the Global Conference for Advancement in Technology (GCAT). 2019. P. 1–6. <https://doi.org/10.1109/GCAT47503.2019.8978403>
39. Sharifi Z., Mohammadi S., Sirjani M. Comparison of NoC Routing Algorithms Using Formal Methods. 2013 [Электронный ресурс]. URL: <https://rebeca-lang.org/assets/papers/2013/NoC-Routing-Algorithms-Comparison.pdf> (дата обращения: 20.02.2024).
40. Saliu M., Momoh M., Chinedu P., Nwankwo W., Daniel A. Comparative performance analysis of selected routing algorithms by load variation of 2-dimensional mesh topology based Network-On-Chip // ELEKTRIKA-Journal of Electrical Engineering. 2021. V. 20. N. 3. P. 1–6. <https://doi.org/10.11113/elektrika.v20n3.249>
41. Kaleem M., Isnin I.F.B. A survey on network on chip routing algorithms criteria // Advances in Intelligent Systems and Computing. 2021. V. 1188. P. 455–466. [https://doi.org/10.1007/978-981-15-6048-4\\_40](https://doi.org/10.1007/978-981-15-6048-4_40)
42. Singh J.K., Swain A.K., Kamal Reddy T.N., Mahapatra K.K. Performance evaluation of different routing algorithms in Network
24. Adamu G., Chejara P., Garko A. Review of deterministic routing algorithm for Network-on-Chip. *International Journal of Advance Research in Science and Engineering*, 2015, vol. 4, spec. issue 1, pp. 123–128.
25. Mahendra C., Gaikwad M., Patrikar R. Review of XY routing algorithm for network-on-chip architecture. *International Journal of Computer and Communication Technology*, 2016, vol. 43, pp. 20–23. <https://doi.org/10.47893/IJCCT.2016.1384>
26. Kumar M., Laxmi V., Gaur M.S., Daneshtalab M., Zwolinski M. A novel non-minimal turn model for highly adaptive routing in 2D NoCs. *Proc. of the 22<sup>nd</sup> International Conference on Very Large Scale Integration (VLSI-SoC)*, 2014, pp. 1–6. <https://doi.org/10.1109/VLSI-SoC.2014.7004192>
27. Brown J.W. *Adaptive Network on Chip Routing using the Turn Model: Master's Theses and Capstones*. 2013. Available at: <https://scholars.unh.edu/thesis/779> (accessed: 20.02.2024)
28. Ahmad K., Sethi M.A.J., Ullah R., Ahmed I., Ullah A., Jan N., Karami G.M. Congestion-aware routing algorithm for NoC using data packets. *Wireless Communications and Mobile Computing*, 2021, vol. 2921. <https://doi.org/10.1155/2021/8588646>
29. Ponnан S., Kumar T.A., Hemakumar V.S., Natarajan S., Shah M.A. Congestion aware low power on chip protocols with network on chip with cloud security. *Journal of Cloud Computing*, 2022, vol. 11, no. 1, pp. 41. <https://doi.org/10.1186/s13677-022-00307-4>
30. Akbar R., Etedalpour A.A., Safaei F. An efficient fault-tolerant routing algorithm in NoCs to tolerate permanent faults. *The Journal of Supercomputing*, 2016, vol. 72, no. 12, pp. 4629–4650. <https://doi.org/10.1007/s11227-016-1749-0>
31. Zhang Z., Serwe W., Wu J., Yoneda T., Zheng H., Myers C. Formal analysis of a fault-tolerant routing algorithm for a Network-on-Chip. *Lecture Notes in Computer Science*, 2014, vol. 8718, pp. 48–62. [https://doi.org/10.1007/978-3-319-10702-8\\_4](https://doi.org/10.1007/978-3-319-10702-8_4)
32. Carara E., Calazans N., Moraes F. Managing QoS flows at task level in NoC-based MPSoCs. *Proc. of the 17<sup>th</sup> IFIP International Conference on Very Large Scale Integration. (VLSI-SoC)*, 2009, pp. 133–138. <https://doi.org/10.1109/VLSISOC.2009.6041343>
33. Xie P., Gu H. Intelligent bees for QoS routing in Networks-on-Chip. *Proc. of the Second Pacific-Asia Conference on Circuits, Communications and System*, 2010, pp. 311–314. <https://doi.org/10.1109/PACCS.2010.5626974>
34. Nedjah N., de Macedo Mourelle L. Routing in Network-on-Chips using ant colony optimization. *Studies in Computational Intelligence*, 2014, vol. 529, pp. 173–198. [https://doi.org/10.1007/978-3-319-03110-1\\_11](https://doi.org/10.1007/978-3-319-03110-1_11)
35. Nedjah N., Silva Junior L., De Macedo Mourelle L. Congestion-aware an colony based routing algorithms for efficient application execution on Network-on-Chip platform. *Expert Systems with Applications*, 2013, vol. 40, no. 16, pp. 6661–6673. <https://doi.org/10.1016/j.eswa.2013.06.005>
36. Ahmad K., Sethi M.A.J. Review of Network on Chip routing algorithms. *EAI Endorsed Transactions on Context-aware Systems and Applications*, 2020, vol. 7, no. 2, pp. e5. <https://doi.org/10.4108/eai.23-12-2020.167793>
37. Xu Y., Zhou J., Liu S. Research and analysis of routing algorithms for NoC. *Proc. of the 3<sup>rd</sup> International Conference on Computer Research and Development*, 2011, pp. 98–102. <https://doi.org/10.1109/ICCRD.2011.5764092>
38. Uma R., Sarojadevi H., Sanju V. Network-On-Chip (NoC) - routing techniques: a study and analysis. *Proc. of the Global Conference for Advancement in Technology (GCAT)*, 2019, pp. 1–6. <https://doi.org/10.1109/GCAT47503.2019.8978403>
39. Sharifi Z., Mohammadi S., Sirjani M. Comparison of NoC Routing Algorithms Using Formal Methods. 2013. Available at: <https://rebeca-lang.org/assets/papers/2013/NoC-Routing-Algorithms-Comparison.pdf> (accessed: 20.02.2024).
40. Saliu M., Momoh M., Chinedu P., Nwankwo W., Daniel A. Comparative performance analysis of selected routing algorithms by load variation of 2-dimensional mesh topology based Network-On-Chip. *ELEKTRIKA-Journal of Electrical Engineering*, 2021, vol. 20, no. 3, pp. 1–6. <https://doi.org/10.11113/elektrika.v20n3.249>
41. Kaleem M., Isnin I.F.B. A survey on network on chip routing algorithms criteria. *Advances in Intelligent Systems and Computing*, 2021, vol. 1188, pp. 455–466. [https://doi.org/10.1007/978-981-15-6048-4\\_40](https://doi.org/10.1007/978-981-15-6048-4_40)
42. Singh J.K., Swain A.K., Kamal Reddy T.N., Mahapatra K.K. Performance evaluation of different routing algorithms in Network

- on Chip // Proc. of the IEEE Asia Pacific Conference on Postgraduate Research in Microelectronics and Electronics (PrimeAsia). 2013. P. 180–185. <https://doi.org/10.1109/PrimeAsia.2013.6731201>
43. Soni N., Deshmukh K. Comparison between three different types of routing algorithms of Network on Chip // Springer Proceedings in Physics. 2015. V. 166. P. 447–459. [https://doi.org/10.1007/978-81-322-2367-2\\_56](https://doi.org/10.1007/978-81-322-2367-2_56)
44. Palesi M., Hölsmark R., Kumar S., Catania V. Application-specific routing algorithms for low power network on chip design // Low Power Networks-on-Chip. Springer, 2011. P. 113–150. [https://doi.org/10.1007/978-1-4419-6911-8\\_5](https://doi.org/10.1007/978-1-4419-6911-8_5)
45. Zulkefli F.W., Ehkan P., Warip M.N.M., Phing N.Y., Zakaria F.F. A comparative review of adaptive routing approach for Network-on-Chip router architecture // Lecture Notes on Data Engineering and Communications Technologies. 2018. V. 5. P. 247–254. [https://doi.org/10.1007/978-3-319-59427-9\\_27](https://doi.org/10.1007/978-3-319-59427-9_27)
46. Hesham S., Rettkowski J., Göhringer D., Abd El Ghany M.A. Survey on real-time network-on-chip architectures // Lecture Notes in Computer Science. 2015. V. 9040. P. 191–202. [https://doi.org/10.1007/978-3-319-16214-0\\_16](https://doi.org/10.1007/978-3-319-16214-0_16)
47. Venkataraman N.L., Kumar R. Design and analysis of application specific network on chip for reliable custom topology // Computer Networks. 2019. V. 158. P. 69–76. <https://doi.org/10.1016/j.comnet.2019.03.014>
48. Madalozzo G., Indrusiak L.S., Moraes F.G. Mapping of real-time applications on a packet switching NoC-based MPSoC // Proc. of the IEEE International Conference on Electronics, Circuits and Systems (ICECS). 2016. P. 640–643. <https://doi.org/10.1109/ICECS.2016.7841283>
49. Soni N., Deshmukh K. Comparison between three different types of routing algorithms of Network on Chip. *Proc. of the IEEE Asia Pacific Conference on Postgraduate Research in Microelectronics and Electronics (PrimeAsia)*, 2013, pp. 180–185. <https://doi.org/10.1109/PrimeAsia.2013.6731201>
50. Soni N., Deshmukh K. Comparison between three different types of routing algorithms of Network on Chip. *Springer Proceedings in Physics*, 2015, vol. 166, pp. 447–459. [https://doi.org/10.1007/978-81-322-2367-2\\_56](https://doi.org/10.1007/978-81-322-2367-2_56)
51. Palesi M., Hölsmark R., Kumar S., Catania V. Application-specific routing algorithms for low power network on chip design. *Low Power Networks-on-Chip*. Springer, 2011, pp. 113–150. [https://doi.org/10.1007/978-1-4419-6911-8\\_5](https://doi.org/10.1007/978-1-4419-6911-8_5)
52. Zulkefli F.W., Ehkan P., Warip M.N.M., Phing N.Y., Zakaria F.F. A comparative review of adaptive routing approach for Network-on-Chip router architecture. *Lecture Notes on Data Engineering and Communications Technologies*, 2018, vol. 5, pp. 247–254. [https://doi.org/10.1007/978-3-319-59427-9\\_27](https://doi.org/10.1007/978-3-319-59427-9_27)
53. Hesham S., Rettkowski J., Göhringer D., Abd El Ghany M.A. Survey on real-time network-on-chip architectures. *Lecture Notes in Computer Science*, 2015, vol. 9040, pp. 191–202. [https://doi.org/10.1007/978-3-319-16214-0\\_16](https://doi.org/10.1007/978-3-319-16214-0_16)
54. Venkataraman N.L., Kumar R. Design and analysis of application specific network on chip for reliable custom topology. *Computer Networks*, 2019, vol. 158, pp. 69–76. <https://doi.org/10.1016/j.comnet.2019.03.014>
55. Madalozzo G., Indrusiak L.S., Moraes F.G. Mapping of real-time applications on a packet switching NoC-based MPSoC. *Proc. of the IEEE International Conference on Electronics, Circuits and Systems (ICECS)*, 2016, pp. 640–643. <https://doi.org/10.1109/ICECS.2016.7841283>

## Авторы

**Бондаренко Михаил Игоревич** — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация; инженер, ООО «Синтакор», Санкт-Петербург, 196247, Российская Федерация, <https://orcid.org/0009-0002-6816-4055>, bondarenko-m-i@yandex.ru

**Платунов Алексей Евгеньевич** — доктор технических наук, профессор, профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0003-3003-3949>, aeplatunov@itmo.ru

Статья поступила в редакцию 11.04.2024  
Одобрена после рецензирования 18.07.2024  
Принята к печати 26.09.2024

## Authors

**Mikhail I. Bondarenko** — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation; Hardware Engineer, Syntacore, Saint Petersburg, 196247, Russian Federation, <https://orcid.org/0009-0002-6816-4055>, bondarenko-m-i@yandex.ru

**Alexey E. Platunov** — D.Sc., Full Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0003-3003-3949>, aeplatunov@itmo.ru

Received 11.04.2024  
Approved after reviewing 18.07.2024  
Accepted 26.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

## ОПТИЧЕСКИЕ СИСТЕМЫ И ТЕХНОЛОГИИ OPTICAL ENGINEERING

doi: 10.17586/2226-1494-2024-24-5-699-708  
УДК 681.586.5

### Исследование характеристик полупроводникового лазерного диода с распределенной обратной связью в режиме источника и приемника оптического излучения для регистрации отклика волоконных решеток Брэгга

Вадим Сергеевич Ошлаков<sup>1</sup>, Артем Сергеевич Алейник<sup>2</sup>,  
Сергей Александрович Волковский<sup>3</sup>, Даниил Сергеевич Смирнов<sup>4</sup>

<sup>1,2,3,4</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>1</sup> voshlakov@mail.ru, <https://orcid.org/0000-0002-2983-4397>

<sup>2</sup> artemal@itmo.ru, <https://orcid.org/0000-0002-7682-348X>

<sup>3</sup> savolkovskii@itmo.ru, <https://orcid.org/0000-0001-8462-5208>

<sup>4</sup> dsmirnov@itmo.ru, <https://orcid.org/0000-0003-4324-9327>

#### Аннотация

**Введение.** Представлены результаты экспериментального исследования возможности применения узкополосного полупроводникового лазерного диода с распределенной обратной связью в качестве источника и приемника оптического излучения для детектирования спектрального отклика волоконной решетки Брэгга. **Метод.** В качестве исследуемого полупроводникового лазерного диода выбран DFB-лазер LDI-1550-DFB-2.5G-20/70 компании Laserscom, серийно выпускаемый на российском рынке и обладающий типовыми характеристиками. Для перестройки центральной длины волны полупроводникового лазерного диода с распределенной обратной связью в диапазоне 1549,5–1552,0 нм использовалась прямая импульсная токовая модуляция с частотой 100 кГц, скважностью 40 и величиной тока 1 А в импульсе. Отраженное от волоконной решетки Брэгга оптическое излучение, соответствующее центральной длине волны Брэгга, регистрировалось за счет фотоэффекта в лазерном диоде. Проведена экспериментальная оценка оптоэлектронных параметров лазерного диода в фотовольтаическом режиме и режиме короткого замыкания: темновой ток, полоса пропускания и спектральная чувствительность. Оценка проводилась при температуре 25 °C. **Основные результаты.** Создана измерительная схема для детектирования отклика волоконной решетки Брэгга. Показано, что фотовольтаический режим лазерного диода применим для задач регистрации оптического излучения. Экспериментально получена амплитудно-частотная характеристика лазерного диода в фотовольтаическом режиме в зависимости от напряжения прямого смещения. Результаты эксперимента: полоса пропускания по уровню –3 дБ составляет 300 МГц, максимальная чувствительность равна 0,1 А/Вт в режиме короткого замыкания, а амплитудный отклик линеен в диапазоне длин волн 1540–1560 нм. Для лазерного диода экспериментально получена вольтамперная характеристика при обратном смещении. Темновой ток при нулевом смещении лазерного диода составляет 12,5 пА. **Обсуждение.** Представленный метод регистрации отклика волоконной решетки Брэгга может быть использован для миниатюризации и упрощения оптических схем измерительных каналов устройств опроса волоконных решеток Брэгга. Полученные результаты могут быть полезны специалистам, занимающимся волоконно-оптическими датчиками и системами сбора и обработки сигналов с таких датчиков.

#### Ключевые слова

волоконные решетки Брэгга, детектирование отклика от ВБР, перестройка центральной длины волны, темновой ток, амплитудно-частотная характеристика

#### Благодарности

Работа выполнена в рамках государственного задания Министерства науки и высшего образования Российской Федерации (проект № FSER-2024-0006).

**Ссылка для цитирования:** Ошлаков В.С., Алейник А.С., Волковский С.А., Смирнов Д.С. Исследование характеристик полупроводникового лазерного диода с распределенной обратной связью в режиме источника и приемника оптического излучения для регистрации отклика волоконных решеток Брэгга // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 699–708. doi: 10.17586/2226-1494-2024-24-5-699-708

© Ошлаков В.С., Алейник А.С., Волковский С.А., Смирнов Д.С., 2024

## Investigation of the characteristics of a semiconductor laser diode as a transceiver for fiber Bragg gratings interrogation

Vadim S. Oshlakov<sup>1</sup>, Artem S. Aleinik<sup>2</sup>, Sergey A. Volkovskiy<sup>3</sup>, Daniil S. Smirnov<sup>4</sup>

<sup>1,2,3,4</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>1</sup> voshlakov@mail.ru, <https://orcid.org/0000-0002-2983-4397>

<sup>2</sup> artemal@itmo.ru, <https://orcid.org/0000-0002-7682-348X>

<sup>3</sup> savolkovskii@itmo.ru, <https://orcid.org/0000-0001-8462-5208>

<sup>4</sup> dsmirnov@itmo.ru, <https://orcid.org/0000-0003-4324-9327>

### Abstract

The paper presents the results of an experimental study of the possibility of using a narrow-band semiconductor distributed feedback laser diode used as a source and detector of optical radiation to detect the spectral response from a fiber Bragg grating. The DFB laser "LDI-1550-DFB-2.5G-20/70" from the company "Laserscom", mass-produced on the Russian market and having standard characteristics, was chosen as the laser diode under study. To sweep the central wavelength of a semiconductor distributed feedback laser diode in the range 1549.5–1552 nm, direct pulse current modulation was used with a frequency of 100 kHz, a duty cycle of 40, and a current value of 1 A per pulse. The radiation reflected from the fiber Bragg grating corresponding to the central Bragg wavelength was recorded as a change in voltage at the anode and cathode of the laser diode due to the photoelectric effect in the laser diode. An experimental assessment of the optoelectronic parameters of a laser diode in photovoltaic and short-circuit modes was carried out: dark current, bandwidth and spectral sensitivity. The evaluation was carried out at a temperature of 25 °C. A measuring circuit has been created to detect the response from a fiber Bragg grating based on direct pulse current modulation and the photovoltaic mode of a semiconductor distributed feedback laser diode. It is shown that the photovoltaic mode of the laser diode is applicable to problems of recording optical radiation. The amplitude-frequency characteristic of a laser diode in the photovoltaic mode was experimentally obtained depending on the forward bias voltage. It is experimentally found that the -3 dB bandwidth is 300 MHz and the maximum sensitivity is 0.1 A/W in short-circuit mode, and the amplitude response is linear in the wavelength range from 1540 to 1560 nm. For the laser diode under study, the reverse branch of the current-voltage characteristic was experimentally obtained and the dark current at zero bias of the laser diode is 12.5 pA. The demonstrated method of FBG interrogation can be used for miniaturization and simplification of optical devices for fiber Bragg grating interrogation. The obtained results may be useful to specialists in fiber optic sensors, system for interrogation and processing signals from fiber optic sensors.

### Keywords

fiber-optic Bragg gratings, FBG interrogation, wavelength sweep, dark current, Bode plot

### Acknowledgements

This research was carried out within the state assignment of the Ministry of Science and Higher Education of the Russian Federation (project No. FSER-2024-0006).

**For citation:** Oshlakov V.S., Aleinik A.S., Volkovskiy S.A., Smirnov D.S. Investigation of the characteristics of a semiconductor laser diode as a transceiver for fiber Bragg gratings interrogation. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 699–708 (in Russian). doi: 10.17586/2226-1494-2024-24-5-699-708

### Введение

Волоконные решетки Брэгга (ВБР) получили широкое распространение в качестве чувствительных элементов (ЧЭ) измерителей физических величин [1], благодаря таким свойствам как компактный размер; высокая чувствительность к температуре и деформации; устойчивость к электромагнитным помехам; возможность мультиплексирования большого количества ЧЭ в рамках одного оптического волокна; отсутствие необходимости организовывать ввод/вывод излучения из оптического волокна и высокая надежность [2].

На сегодняшний день существуют два метода измерений спектрального отклика ВБР: спектрометрия (использование широкополосного источника излучения и спектроанализатора или монохроматора) [3] и перестраиваемая лазерная спектроскопия (метод временного сканирования центральной длины волны узкополосного источника оптического излучения) [4].

К достоинствам спектрометрии стоит отнести высокое разрешение по длине волны (выше 0,5 пм) и широкий диапазон длин волн (от 100 нм). К недостаткам

относятся большие габариты, сравнительно низкая частота опроса (ниже 50 кГц) и эксплуатационные характеристики, не позволяющие использовать такие приборы в условиях агрессивного воздействия окружающей среды (удары, резкие изменения температур в широком диапазоне и т. д.).

Достоинствами перестраиваемой лазерной спектроскопии являются: малые габаритные размеры; высокая частота опроса (выше 50 кГц); возможность временного мультиплексирования ВБР (т. е. при аналогичной частоте опроса одиночной решетки при использовании спектрометрии, спектроскопия позволяет опрашивать несколько ВБР на одной длине волны, разнесенные по времени отклика). Из недостатков отметим более низкое разрешение по длине волны (1–10 пм), по сравнению с спектрометрией и ограниченный диапазон длин волн (5–10 нм) на один измерительный канал.

Общим недостатком обоих методов является высокая стоимость блоков опроса. Для снижения себестоимости блоки опроса проектируются таким образом, чтобы снизить стоимость одного измерительного канала, но из-за высокой стоимости имеющихся техни-

ческих решений приемлемая стоимость блоков опроса достигается только в сложных дорогостоящих многоканальных системах.

На практике часто возникает необходимость опроса единичного или небольшого массива ЧЭ на основе ВБР, в связи с чем актуальной является задача миниатюризации, повышения надежности и удешевления устройств обработки сигналов от таких ЧЭ [5–8].

Применение широко распространенной телекоммуникационной элементной базы позволяет существенно снизить стоимость современных сенсорных систем различного типа. Среди телекоммуникационных полупроводниковых лазеров, подходящих для опроса ВБР методом сканирования центральной длины волн, выделим поверхностно-излучающие лазеры с вертикальным резонатором (Vertical-Cavity Surface-Emitting, VCSEL) и лазеры с распределенной обратной связью (Distributed Feedback, DFB).

Известны методы перестройки центральной длины волн таких лазеров при помощи прямой импульсной токовой модуляции [9–11]. Ключевым недостатком VCSEL является то, что коммерчески доступные лазеры, излучающие на длинах волн 1,3 мкм или 1,5 мкм, производят небольшое количество компаний. В свою очередь DFB-лазеры имеют более широкую номенклатуру и низкую стоимость из-за хорошо отработанной технологии производства и широкого распространения в качестве источников излучения для телекоммуникационных приемо-передатчиков, что делает такие лазеры более привлекательными при использовании в устройствах опроса ВБР.

В объемной оптике широко известным является метод автодинной интерферометрии [12]. Ключевой особенностью данного метода является использование лазера в качестве источника излучения и интерферометра, а встроенный в лазер фотодиод, предназначенный для контроля оптической мощности, применяется для детектирования интерференционного сигнала. Основным недостатком данного метода являются низкие чувствительность и полоса пропускания встроенного в лазер фотодиода. В работе [13] продемонстрировано детектирование сигналов автодинной интерферометрии за счет изменения напряжения на аноде и катоде лазерного диода, тем самым лазерный диод является источником и приемником излучения. В сравнении со встроенным фотодиодом такой метод позволяет обеспечить полосу частот приема сигналов, сопоставимую с полосой частоты модуляции излучения лазера. Стоит отметить, что основные оптоэлектронные характеристики лазера в режимах короткого замыкания и фотовольтаическом режиме не паспортизируются и не приводятся в документации производителями.

Ключевыми параметрами лазерного диода, использующегося в качестве приемника оптического излучения, являются: чувствительность в диапазоне длин волн (А/Вт); темновой ток (пА) и амплитудно-частотная характеристика.

В настоящей работе предложен метод детектирования спектрального отклика ВБР, основанный на использовании DFB-лазера в качестве источника и приемника оптического излучения. Перестройка центральной дли-

ны волн лазера осуществляется посредством прямой импульсной токовой модуляции. Отраженное от ВБР излучение детектируется за счет фотоэффекта в лазерном диоде в моменты отсутствия токового импульса.

Цель работы — исследование оптоэлектронных характеристик полупроводникового DFB-лазера в режиме короткого замыкания (КЗ) и фотовольтаическом режиме.

### Перестраиваемая лазерная спектроскопия для опроса ВБР

Типовая схема устройства, реализующего метод перестройки лазерной спектроскопии для детектирования спектрального отклика от ВБР (рис. 1), включает: перестраиваемый по длине волн источник излучения, оптический циркулятор и фотодиод. Часто циркулятор заменяют на Y-ответвитель и изолятар [14] для защиты источника излучения от обратных отражений. Центральная длина волн источника излучения 2 перестраивается прямым токовым импульсом формируемым генератором импульсов 1 в диапазоне длин волн от  $\lambda_1$  до  $\lambda_N$  за время  $T$ , при этом каждому моменту времени в импульсе соответствует некоторая величина  $\lambda$ . Импульс оптического излучения с мощностью  $P$  и длительностью  $T$  проходит по волокну расстояние  $L$  и от ВБР 4 отражается излучение, соответствующее центральной длине волн Брэгга  $\lambda_{\text{ВБР}}$ . Отраженное излучение проходит в обратном направлении расстояние  $L$  и через циркулятор 3 попадает на фотодиод 5, где преобразуется в электрический сигнал, поступающий на счетчик времени 6 вместе с исходным импульсом генератора. Счетчик времени определяет время от начала импульса перестройки центральной длины волн, поданного на лазерный диод до прихода на фотодиод излучения, отраженного от ВБР. При механическом или температурном воздействиях на ВБР  $\lambda_{\text{ВБР}}$  смещается, в результате счетчик времени регистрирует разницу по времени между импульсом перестройки центральной длины волн источника излучения и зарегистрированным импульсом на фотодиоде.

Представленный метод опроса ВБР позволяет упростить типовую схему устройства, реализующего метод сканирования центральной длины волны узкополосного источника излучения до лазерного диода и ВБР.

В качестве исследуемого лазерного диода выбран DFB-лазер LDI-1550-DFB-2.5G-20/70 от компании Laserscom, серийно выпускаемый на российском рынке и обладающий следующими типовыми параметрами: центральная длина волны 1550 нм, максимальная выходная мощность 70 мВт, ширина спектра 80 пм, частота модуляции до 2,5 ГГц.

### Метод перестройки центральной длины волны DFB-лазера

Метод перестройки центральной длины волны DFB-лазера описан в работе [15] и основан на температурном сдвиге центральной длины волны лазера в результате кратковременного разогрева активной области импульсным током высокой плотности на кристалле.

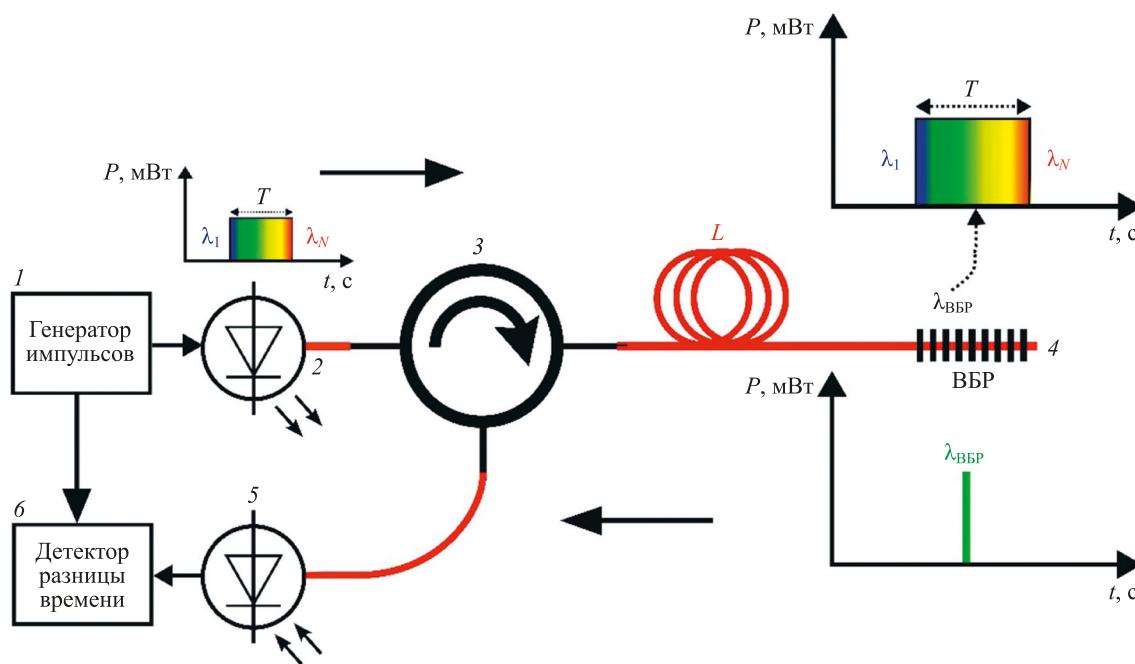


Рис. 1. Типовая схема устройства детектирования отклика от волоконной решетки Брэгга при помощи метода перестройки центральной длины волны узкополосного источника излучения:

1 — генератор импульсов; 2 — источник излучения; 3 — циркулятор; 4 — волоконная решетка Брэгга (ВБР); 5 — фотодиод; 6 — счетчик времени

*Fig. 1. Typical fiber Bragg grating interrogation system based on wavelength-swept laser diode.*

1 — pulse generator; 2 — light source; 3 — circulator; 4 — fiber Bragg grating (BFR); 5 — photodiode; 6 — time measurement unit

Перестройка центральной длины волны на 10 нм осуществляется за счет модуляции короткими импульсами тока, величина которых на несколько порядков выше рабочего тока лазера и составляет 4 А.

На исследуемый лазерный диод подаются токовые импульсы с периодом 10 мкс и длительностью 250 нс. Диапазон перестройки величины тока в импульсе составил от 0,04 до 1 А, ток при этом увеличивался с шагом 40 мА. Зарегистрированные спектры излучения лазера при перестройке центральной длины волны в зависимости от величины тока модуляции показаны на рис. 2.

Для регистрации спектров использован оптический спектроанализатор Yokogawa AQ6370C. Период цикла сканирования в спектральном диапазоне от 1500 до 1600 нм составляет 0,2 с, поэтому нарушается принцип инвариантности и спектры перестройки центральной длины волны DFB-лазера имеют вид сплошных. Нелинейная форма спектрального отклика перестройки частоты излучения лазера при постоянном токе в импульсе свидетельствует о нелинейности скорости перестройки центральной длины волны лазера [16]. На спектрограмме нелинейность скорости перестройки центральной длины проявляется как постепенное изменение уровня мощности на границах диапазона перестройки.

Типовой сдвиг центральной длины волны Брэгга для ВБР, использующейся в качестве ЧЭ в волоконно-оптических спектрально-селективных системах измерения температуры [17], составляет 10 пм/К. Для обеспечения работы в диапазоне температур от минус 40 °С до 120 °С, необходимо обеспечить диапазон пе-

рестройки центральной длины волны лазера на 1,6 нм. Полученного диапазона перестройки центральной длины волны (2,5 нм) DFB-лазера достаточно для опроса одной ВБР в приведенном температурном диапазоне в качестве ЧЭ для измерения температуры.

#### Амплитудно-частотная характеристика DFB-лазера в фотовольтаическом режиме

Так как метод перестройки центральной длины волны DFB-лазера основан на прямой импульсной токовой модуляции с длительностью импульсов 250 нс, то для детектирования отклика от ВБР с использованием фотовольтаического режима лазерного диода, его полоса пропускания в этом режиме не должна ограничивать полосу регистрируемого сигнала.

В рамках настоящей работы выполнена оценка частотных параметров DFB-лазера в фотовольтаическом режиме и в режиме КЗ. Измерения проводились при помощи схемы, представленной на рис. 3. Принцип измерения основан на регистрации коэффициента передачи S21 DFB-лазера в фотовольтаическом режиме в диапазоне частот от 50 кГц до 300 МГц при помощи векторного анализатора цепей.

В качестве источника излучения применен лабораторный суперлюминесцентный диод от компании Thorlabs, модель S5FC1005P 1 с центральной длиной волны 1550 нм, обладающий шириной спектра равной 50 нм и регулируемой выходной мощностью оптического излучения. Выходное излучение источника линейно поляризовано, что позволяет при использовании

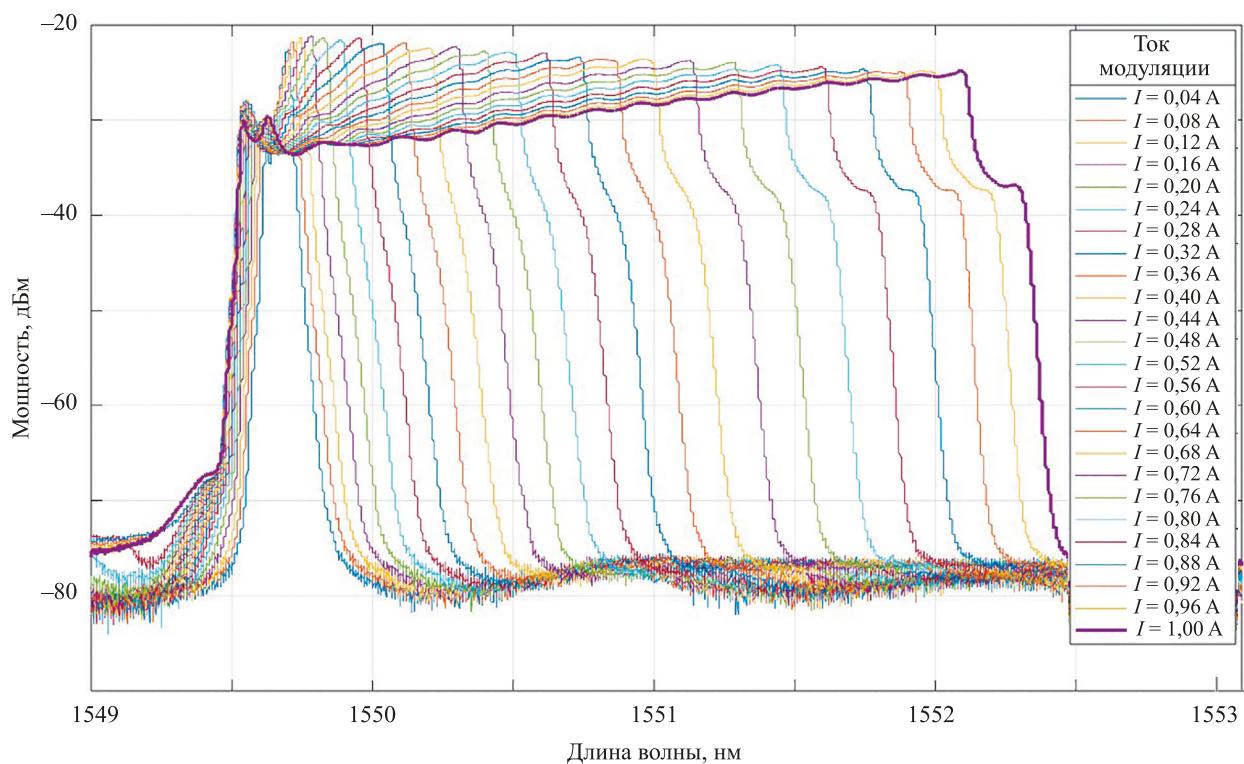


Рис. 2. Спектры перестройки центральной длины волны DFB-лазера при разных токах модуляции  
Fig. 2. Spectrums of the central wavelength sweeping at different modulation currents of the DFB laser diode

оптического волокна, сохраняющего состояние поляризации, согласовать рабочие поляризационные оси источника излучения и входного оптического волокна модулятора, обеспечив максимальную глубину модуля-

ции модулятором Маха–Цендера (ММЦ) 2 (компания JDS Uniphase, модель 10023707).

Оптическое излучение источника модулируется при помощи амплитудного модулятора гармоническим сиг-

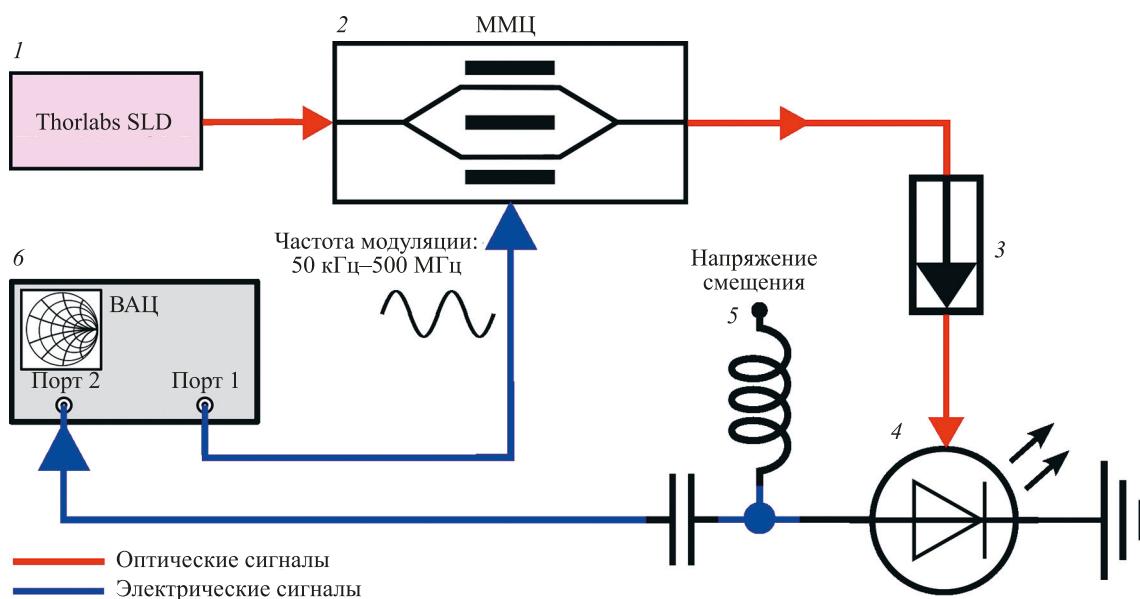


Рис. 3. Блок-схема стенда для оценки частотных характеристик DFB-лазера в фотовольтаическом режиме при различных напряжениях смещения:  
1 — источник излучения; 2 — модулятор Маха–Цендера (ММЦ); 3 — оптический изолятар; 4 — DFB-лазер; 5 — LC-фильтр;

6 — векторный анализатор цепей (ВАЦ)

Fig. 3. Measurement frequency characteristics setup of the DFB laser diode in the photovoltaic mode at different bias voltages:

1 — light source; 2 — Mach-Zender modulator (MMZ); 3 — optical isolator; 4 — DFB laser diode; 5 — LC-filter;  
6 — vector network analyzer (VAZ)

налом с частотой в диапазоне от 50 кГц до 300 МГц, поступающим с порта 1 векторного анализатора цепей компании Siglent, модель 4502 6. Амплитудно-модулированное излучение через изолятар 3 подается на вход исследуемого лазерного диода 4, где за счет фотоэффекта преобразуется в электрический сигнал. Оптический изолятар 3 использован для предотвращения возникновения неконтролируемой лазерной генерации суперлюминесцентного диода, которая может привести к выходу из строя.

Электрический отклик с исследуемого лазерного диода регистрируется входным портом векторного анализатора цепей (ВАЦ). В результате получен набор коэффициентов передачи исследуемого лазерного диода (S21) при прямом смещении диода в диапазоне от 0 до 0,9 В. Напряжение смещения при помощи лабораторного блока питания компании Rohde&Schwartz, модель NGL202 подается на DFB-лазер через LC-фильтр компании MiniCircuits, модель ZX85-12G-S+ 5, предотвращающий шунтирование блока питания с портом 2 векторного анализатора цепей. Диапазон изменения напряжения смещения, подаваемого с лабораторного блока питания, составил от 0 до 0,9 В с шагом 10 мВ.

Амплитудно-частотные характеристики исследуемого лазерного диода в диапазоне напряжений прямого смещения показаны на рис. 4.

С увеличением прямого напряжения смещения лазерный диод из режима КЗ переходит в фотовольтаический режим, что приводит к снижению электрического отклика на внешнее оптическое излучение вплоть до 0,75 В, соответствующего пороговому напряжению согласно его паспортной вольтамперной характеристике. При напряжении смещения 0,85 В наблюдается амплитудный отклик во всей полосе частот, ток через лазер соответствует значению 7 мА, при этом уровень выходной мощности оптического излучения лазера сопоставим с мощностью модулируемого источника излучения (1 мВт). В работе [14] такой эффект описан как оптическая инжекция, на частотных характеристи-

ках это проявляется как амплитудный всплеск электрического сигнала. Дальнейшее увеличение напряжения прямого смещения лазерного диода согласно теории полупроводников приводит к снижению дрейфового напряжения в *PN*-переходе и росту диффузационного тока через диод, что вызывает рост величины излучаемой оптической мощности. Под воздействием оптического излучения в активной области происходит генерация фотоиндущированных электронно-дырочных пар, поэтому снижение дрейфового напряжения внешним электрическим полем приводит к увеличению рекомбинации фотоиндущированных носителей в активной области, при этом величина фототока падает и становится малоразличимой в сравнении с растущим прямым диффузационным током.

При воздействии внешнего оптического излучения DFB-лазер имеет наибольший амплитудный отклик во всей полосе частот и обладает наибольшей чувствительностью и полосой пропускания по уровню  $-3$  дБ равной 300 МГц при напряжении смещения, соответствующем 0 В, т. е. в режиме КЗ. С ростом частоты амплитудной модуляции внешнего излучения наблюдается незначительное снижение величины электрического амплитудного отклика, что может быть связано с несовпадением волновых сопротивлений входного порта векторного анализатора цепей и DFB-лазера.

Полученной полосы пропускания равной 300 МГц в режиме КЗ достаточно для регистрации спектрального отклика от ВБР во временной области.

#### Спектральная чувствительность и темновой ток лазерного диода в фотодиодном режиме

Темновой ток и спектральная чувствительность определяют пороговую чувствительность фотоприемника. Для детектирования спектрального отклика от ВБР необходимо, чтобы при фотоэффекте электрический отклик исследуемого лазерного диода в режиме КЗ был линеен и независим от длины волны внешнего оптического излучения, а темновой ток был сопоставим с темновым током *PIN*-фотодиодов, использующихся в измерительных схемах. Типовая чувствительность *PIN*-фотодиодов близка к 1 А/Вт. Величина темнового тока *PIN*-фотодиодов составляет десятки пикоампер (фотодиод от компании Laserscom, модель PDI-80-P10-2G-K, обладающий чувствительностью 1 А/Вт в диапазоне длин волн 1400–1650 нм и темновым током величиной 30 пА).

Схема измерения темнового тока, показана на рис. 5. Пикоамперметр компании Keithley, модель 6487 позволяет измерять токи с разрешением  $10^{-14}$  А и точностью 0,3 %, имеет встроенный регулируемый источник напряжения для смещения *PN*-перехода исследуемого лазерного диода в прямом и обратном направлениях, что подходит для измерения фототока и темнового тока фотодиодов. Измерения проводились при температуре 25 °С без воздействия оптического излучения на DFB-лазер.

Измеренная обратная ветвь вольтамперной характеристики DFB-лазера представлена на рис. 6. Темновой ток в режиме КЗ (при нулевом напряжении смещения

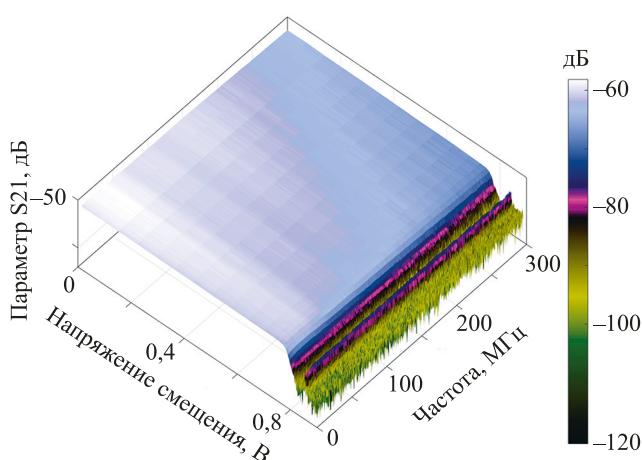


Рис. 4. Зависимость коэффициента передачи S21 DFB-лазера в фотовольтаическом режиме от величины напряжения прямого смещения

Fig. 4. Transmission coefficient S21 of the DFB laser diode in photovoltaic mode at different bias voltages



Рис. 5. Схема измерения темнового тока DFB-лазера  
Fig. 5. Measurement dark current setup of the DFB laser diode

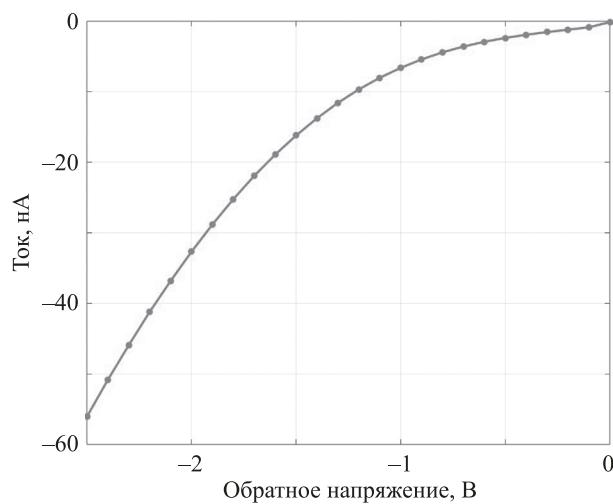


Рис. 6. Обратная ветвь вольтамперной характеристики DFB-лазера  
Fig. 6. Current-voltage characteristic reverse branch of the DFB laser diode

лазера) составляет 12,5 пА, при увеличении обратного напряжения смещения до  $-2,5$  В увеличивается до 55 нА. Темновой ток в режиме КЗ сопоставим с темновыми токами PIN-фотодиодов, используемых в измерительных схемах. В режиме КЗ DFB-лазер может быть применен для детектирования оптического излучения от ВБР или других волоконно-оптических спектральных датчиков.

Для измерения спектральной чувствительности DFB-лазера использовалась схема, представленная на рис. 7.

В качестве внешнего источника излучения выбран перестраиваемый лазер компании Keysight, модель

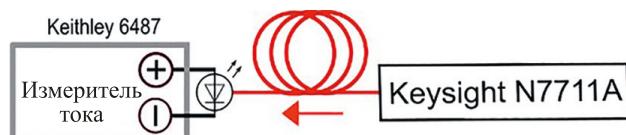


Рис. 7. Схема измерения чувствительности DFB-лазера в режиме короткого замыкания  
Fig. 7. Measurement sensitivity setup of the DFB laser diode in short circuit mode

N7711A с возможностью регулировки выходной мощности и центральной длины волн. На вход исследуемого лазерного диода подавалось оптическое излучение в диапазоне 0–20 мВт с шагом 2,5 мВт на трех длинах волн 1540, 1550 и 1560 нм. Регистрация тока производилась с помощью пикоамперметра (рис. 8).

Чувствительность DFB-лазера получена при нулевом напряжении смещения и, согласно рис. 8, составляет 0,1 А/Вт. Отклик лазерного диода на поступающую входную оптическую мощность линеен и не имеет зависимости от длины волн в диапазоне сканирования. Чувствительность лазерного диода на порядок ниже, чем типовые значения чувствительности у PIN-фотодиодов, использующихся в измерительных схемах в диапазоне длин волн от 1540 до 1560 нм, однако уровня чувствительности в 0,1 А/Вт достаточно для детектирования мощности оптического излучения отклика от ВБР или других волоконно-оптических спектральных датчиков удаленных на расстояние в пределах 10 км.

#### Регистрация отклика ВБР при помощи DFB-лазера в режиме приемо-передатчика

Для проведения измерения была изготовлена ВБР в телекоммуникационном оптическом волокне SMF-28 стандарта G.657.A1 (диаметры световедущей жилы — около 10 мкм, оболочки — 125 мкм и защитного акрилатного покрытия — 250 мкм) при помощи схемы записи на основе интерферометра Тальбота [18].

Параметры ВБР: центральная длина волны (при температуре 25 °C) — 1551 нм, ширина спектра — 0,22 нм (по уровню  $-3$  дБ), температурный сдвиг центральной длины волн — 10 пм/К, коэффициент отражения — 90 %.

На рис. 9 представлена блок-схема макета для экспериментальной проверки работоспособности предложенного метода опроса ВБР при помощи DFB-лазера в режимах источника и приемника оптического излучения. Измерения проводились при комнатной темпе-

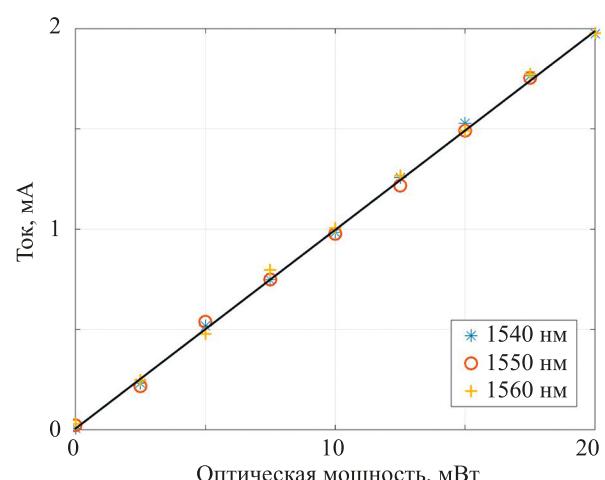


Рис. 8. Зависимость фототока DFB-лазера в режиме короткого замыкания от мощности входного оптического излучения для длин волн 1540, 1550 и 1560 нм  
Fig. 8. Photocurrent dependence of the DFB laser diode in short circuit mode at wavelength 1540 nm, 1550 nm, 1560 nm

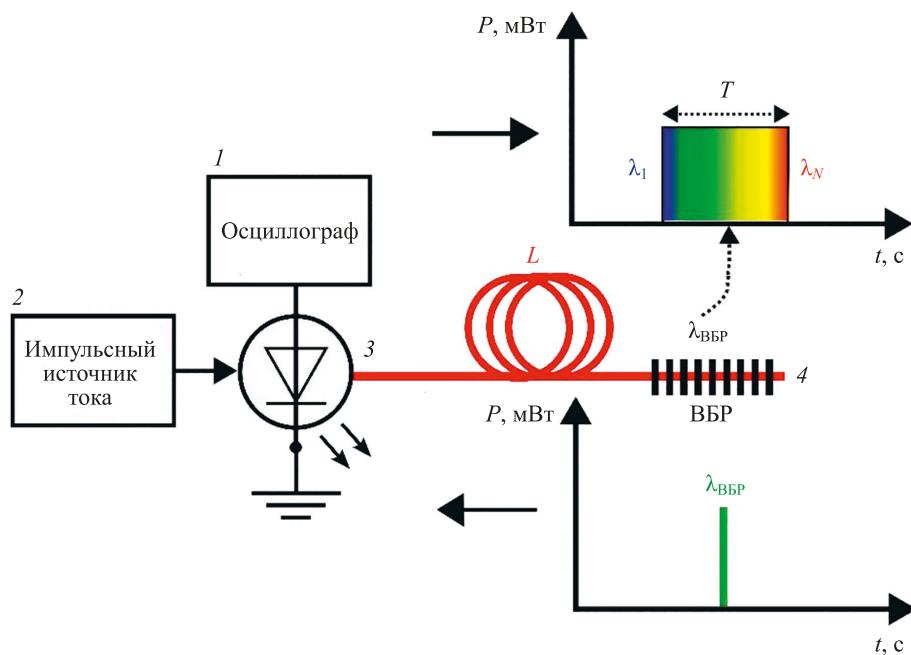


Рис. 9. Блок-схема макета для опроса волоконной решетки Брэгга (ВБР) при помощи DFB-лазера в режиме приемника и передатчика оптического излучения:

1 — осциллограф; 2 — импульсный источник тока; 3 — исследуемый лазерный диод; 4 — волоконная решетка Брэгга (ВБР)

Fig. 9. Measurement setup for fiber Bragg grating interrogation system using DFB laser in the receiver and transmitter mode of optical power:

1 — oscilloscope; 2 — pulse current source; 3 — laser diode; 4 — fiber Bragg grating (ВБР)

туре 25 °C. На лазерный диод 3 подавались импульсы тока величиной 1 А с длительностью 250 нс и периодом следования 10 мкс при помощи импульсного источника тока 2. Диапазон перестройки центральной длины волны составил 2,5 нм в соответствии с рис. 2.

Импульс оптического излучения с постоянной мгновенной мощностью и изменяющейся длиной волны формируемый лазерным диодом длительностью  $\tau = 250$  нс проходит по волокну расстояние 100 м, и от ВБР 4 отражается оптическое излучение с длиной волны, соответствующей центральной длине волны Брэгга — 1551 нм ( $\lambda_{\text{BFR}}$  на рис. 9). Отраженное от ВБР излучение проходит в обратном направлении расстояние, равное 100 м и приходит на DFB-лазер в момент времени, когда напряжение на лазерном диоде упало до 0 В, где за счет фотоэффекта преобразуется в электрический отклик. Отклик от ВБР в виде напряжения на лазерном диоде детектируется при помощи осциллографа компании Rhode&Schwarz, модель RTO1024 1.

На рис. 10 представлен результат детектирования спектрального отклика от ВБР.

В результате температурного воздействия на ВБР происходит сдвиг центральной длины волны Брэгга. Так как центральной длине волны лазера при перестройке можно сопоставить некоторый момент времени из длительности  $\tau$ , то сдвиг центральной длины ВБР во временной области приводит к изменению задержки между импульсом модуляции и отраженным от ВБР излучением.

Изменение задержки по времени между импульсом модуляции и отраженным от ВБР излучением соответствует 700 пс при сдвиге центральной длины волны

ВБР соответствующем 10 пм, что эквивалентно изменению температуры ВБР на 1 °C. Величина сдвига центральной длины волны фиксировалась спектроанализатором по излучению прошедшему через ВБР.

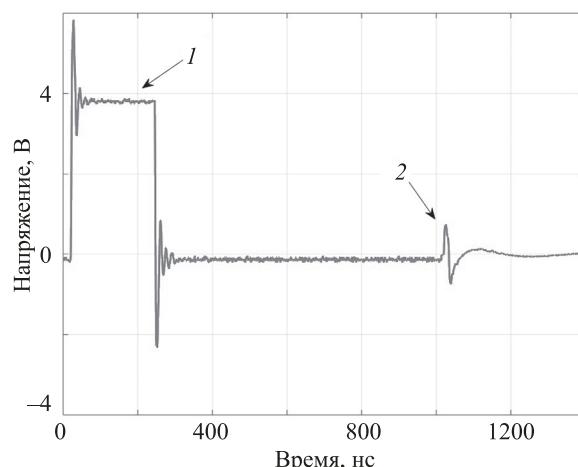


Рис. 10. Осциллограмма зарегистрированного отклика от волоконной решетки Брэгга (ВБР) при помощи DFB-лазера в режиме источника и приемника оптического излучения:

1 — импульс модуляции лазера; 2 — электрический отклик, вызванный отражением от ВБР, зарегистрированный при помощи DFB-лазера в фотовольтаическом режиме

Fig. 10. Waveform of the recorded FBG signal using DFB laser diode in the receiver and transmitter mode of optical power:

1 — laser modulation pulse; 2 — electrical response of the DFB laser diode in the photovoltaic mode induced by FBG reflection

Длительности импульсов отраженного от ВБР излучения (2 на рис. 10) накладывают высокие требования к аппаратуре регистрации и обработки отклика от ВБР в части высокой частоты дискретизации (выше  $6 \cdot 10^8$  Гц) и обеспечения аналоговой полосы пропускания тракта выше 300 МГц. Использование современных преобразователей время-цифровой код [19] для детектирования временной задержки между импульсами измерениях может существенно снизить требования к электронной части опроса ВБР с сохранением высокого разрешения по центральной длине волны не менее 10 пм.

### Заключение

Представлен метод опроса волоконных решеток Брэгга при помощи исследуемого лазерного диода (DFB-лазера) в режиме источника и приемника излучения. Проведена оценка типовых характеристик DFB-лазера в режиме приемника оптического излучения. По полученным данным можно сделать вывод о возможности использования DFB-лазера для детектирования отклика от волоконной решетки Брэгга в режиме короткого замыкания и в фотовольтаическом режиме. При нулевом смещении лазерного диода наблюдается самый низкий темновой ток 12,5 пА и наибольший электрический отклик на входное оптическое излучение в диапазоне длин волн от 1540 до 1560 нм. Подтверждено, что полоса пропускания DFB-лазера в фотовольтаическом режиме и в режиме короткого замыкания позволяет использовать лазер для детектирования

сигналов в полосе частот до 300 МГц при частотах опроса чувствительных элементов на уровне 100 кГц и выше, что может быть применено при построении высокоскоростных измерителей на основе волоконных решеток Брэгга. Диапазон перестройки центральной длины волны лазера может быть расширен с 2,5 нм до 5 нм и выше за счет увеличения величины прямого тока в импульсе, что достаточно для опроса двух чувствительных элементов с мультиплексированием по длине волны в одном оптическом волокне. При величине характерного сдвига центральной длины волны датчика температуры на основе волоконной решетки Брэгга (10 пм/К), полученного диапазона перестройки центральной длины волны (2,5 нм) и разрешения (700 пс/К), достаточно для опроса датчика температуры в диапазоне изменения температуры от минус 70 °C до 150 °C с разрешением выше 1 °C. Предложенная схема и метод позволяют без механических компонентов и при минимальном количестве оптических элементов производить опрос чувствительного элемента на основе волоконных решеток Брэгга. Использование DFB-лазера в режиме источника и приемника оптического излучения позволяет снизить стоимость схемы опроса чувствительных элементов на основе волоконных решеток Брэгга, расширить диапазон применимости схемы за счет ее миниатюризации, меньшей чувствительности к внешним вибрационным и ударным воздействиям из-за отсутствия подвижных механических элементов, в отличие от классических анализаторов спектра и перестраиваемых лазеров, а также существенно увеличить частоту опроса.

### Литература

1. Fiber Bragg Grating Sensors: Recent Advancements, Industrial Applications and Market Exploitation / ed. by A. Cusano, A. Cutolo, J. Albert. Bentham Science Publishers, 2011. <https://doi.org/10.2174/9781608050840110101>
2. Chen J., Liu B., Zhang H. Review of fiber Bragg grating sensor technology // *Frontiers of Optoelectronics in China*. 2011. V. 4. N. 2. P. 204–212. <https://doi.org/10.1007/s12200-011-0130-4>
3. Silveira P.C., Dante A., Keley M.M., Carvalho C., Allil R., Mok R., Garcao L., Werneck M. Experimental evaluation of low-cost interrogation techniques for FBG sensors // Proc. of the IEEE International Instrumentation and Measurement Technology Conference (I2MTC). 2018. P. 1–6. <https://doi.org/10.1109/i2mtc.2018.8409722>
4. Lee H.S., Lee H., Kim H., Cho J., Jeong M., Kim C.-S. A fiber Bragg grating sensor interrogation system based on a linearly wavelength-swept thermo-optic laser chip // *Sensors*. 2014. V. 14. N. 9. P. 16109–16116. <https://doi.org/10.3390/s140916109>
5. Flores-Bravo J.A., Madrigal J., Zubia J., Sales S., Villatoro J. Coupled-core fiber Bragg gratings for low-cost sensing // *Scientific Reports*. 2022. V. 12. N 1. P. 1280. <https://doi.org/10.1038/s41598-022-05313-9>
6. Yang F., Zhang W., Zhao S., Liu Q., Tao J., He Z. Miniature interrogator for multiplexed FBG strain sensors based on a thermally tunable microring resonator array // *Optics Express*. 2019. V. 27. N. 5. P. 6037–6046. <https://doi.org/10.1364/oe.27.006037>
7. Darwich D., Youssef A., Zaraket H. Low-cost multiple FBG interrogation technique for static applications // *Optics Letters*. 2020. V. 45. N. 5. P. 1116–1119. <https://doi.org/10.1364/ol.386053>
8. Darwich D., Youssef A., Pisco M., Zaraket H. Investigation of low-cost interrogation technique based on modulated distributed feedback laser // *IEEE Sensors Journal*. 2020. V. 20. N 5. P. 2460–2466. <https://doi.org/10.1109/jsen.2019.2951436>

### References

1. *Fiber Bragg Grating Sensors: Recent Advancements, Industrial Applications and Market Exploitation*. Ed. by A. Cusano, A. Cutolo, J. Albert. Bentham Science Publishers, 2011. <https://doi.org/10.2174/9781608050840110101>
2. Chen J., Liu B., Zhang H. Review of fiber Bragg grating sensor technology. *Frontiers of Optoelectronics in China*, 2011, vol. 4, no. 2, pp. 204–212. <https://doi.org/10.1007/s12200-011-0130-4>
3. Silveira P.C., Dante A., Keley M.M., Carvalho C., Allil R., Mok R., Garcao L., Werneck M. Experimental evaluation of low-cost interrogation techniques for FBG sensors. *Proc. of the IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 2018, pp. 1–6. <https://doi.org/10.1109/i2mtc.2018.8409722>
4. Lee H.S., Lee H., Kim H., Cho J., Jeong M., Kim C.-S. A fiber Bragg grating sensor interrogation system based on a linearly wavelength-swept thermo-optic laser chip. *Sensors*, 2014, vol. 14, no. 9, pp. 16109–16116. <https://doi.org/10.3390/s140916109>
5. Flores-Bravo J.A., Madrigal J., Zubia J., Sales S., Villatoro J. Coupled-core fiber Bragg gratings for low-cost sensing. *Scientific Reports*, 2022, vol. 12, no. 1, pp. 1280. <https://doi.org/10.1038/s41598-022-05313-9>
6. Yang F., Zhang W., Zhao S., Liu Q., Tao J., He Z. Miniature interrogator for multiplexed FBG strain sensors based on a thermally tunable microring resonator array. *Optics Express*, 2019, vol. 27, no. 5, pp. 6037–6046. <https://doi.org/10.1364/oe.27.006037>
7. Darwich D., Youssef A., Zaraket H. Low-cost multiple FBG interrogation technique for static applications. *Optics Letters*, 2020, vol. 45, no. 5, pp. 1116–1119. <https://doi.org/10.1364/ol.386053>
8. Darwich D., Youssef A., Pisco M., Zaraket H. Investigation of low-cost interrogation technique based on modulated distributed feedback laser. *IEEE Sensors Journal*, 2020, vol. 20, no. 5, pp. 2460–2466. <https://doi.org/10.1109/jsen.2019.2951436>

9. Qiao P., Cook K.T., Li K., Chang-Hasnain C.J. Wavelength-swept VCSELs // *IEEE Journal of Selected Topics in Quantum Electronics*. 2017. V. 23. N 6. P. 1700516. <https://doi.org/10.1109/jstqe.2017.2707181>
10. Алейник А.С., Киреенков А.Ю., Мехреньгин М.В., Чиргин М.А., Беликин М.Н. Подстройка центральной длины волны источника оптического излучения в интерферометрических датчиках на основе волоконных брэгговских решеток // Научно-технический вестник информационных технологий, механики и оптики. 2015. Т. 15. № 5. С. 809–816. <https://doi.org/10.17586/2226-1494-2015-15-5-809-816>
11. Njegovec M., Donagic D. Rapid and broad wavelength sweeping of standard telecommunication distributed feedback laser diode // *Optics Letters*. 2013. V. 38. N 11. P. 1999–2001. <https://doi.org/10.1364/ol.38.001999>
12. Liu B., Ruan Y., Yu Y., Xi J., Guo Q., Tong J., Rajan G. Laser self-mixing fiber Bragg grating sensor for acoustic emission measurement // *Sensors*. 2018. V. 18. N 6. P. 1956. <https://doi.org/10.3390/s18061956>
13. Lim Y.L., Bertling K., Rio P., Tucker J.R., Rakic A.D. Displacement and distance measurement using the change in junction voltage across a laser diode due to the self-mixing effect // *Proceedings of SPIE*. 2006. V. 6038. P. 60381O. <https://doi.org/10.1117/12.638433>
14. Liu Z., Slavík R. Optical injection locking: From principle to applications // *Journal of Lightwave Technology*. 2020. V. 38. N 1. P. 43–59. <https://doi.org/10.1109/jlt.2019.2945718>
15. Njegovec M., Donagic D. Interrogation of FBGs and FBGs arrays using standard telecom DFB diode // *Journal of Lightwave Technology*. 2016. V. 34. N 22. P. 5340–5348. <https://doi.org/10.1109/jlt.2016.2616725>
16. Беликин М.Н. Быстродействующее малогабаритное устройство регистрации спектрального отклика для волоконно-оптических датчиков на брэгговских решетках: диссертация на соискание ученой степени кандидата технических наук : 05.11.01 / Университет ИТМО. Санкт-Петербург, 2017. 131 с.
17. Tudose M., Enciu D., Ursu I. Towards use of Fiber Bragg Grating sensors for structural health monitoring of (aero) space structures // *International Journal of Modeling and Optimization*. 2018. V. 8. N 4. P. 246–249. <https://doi.org/10.7763/ijmo.2018.v8.659>
18. Gribaev A.I., Pavlishin I.V., Stam A.M., Idrisov R.F., Varzhel S.V., Konnov K.A. Laboratory setup for fiber Bragg gratings inscription based on Talbot interferometer // *Optical and Quantum Electronics*. 2016. V. 48. N 12. P. 540. <https://doi.org/10.1007/s11082-016-0816-3>
19. Henzler S. *Time-to-Digital Converter Basics*. Springer Netherlands, 2010. P. 5–18. [https://doi.org/10.1007/978-90-481-8628-0\\_2](https://doi.org/10.1007/978-90-481-8628-0_2)

## Авторы

**Ошлаков Вадим Сергеевич** — начальник группы, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57442309800](https://orcid.org/0000-0002-2983-4397), <https://orcid.org/0000-0002-2983-4397>, voshlakov@mail.ru

**Алейник Артем Сергеевич** — кандидат технических наук, доцент, заведующий лабораторией, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 54793978900](https://orcid.org/0000-0002-7682-348X), <https://orcid.org/0000-0002-7682-348X>, artemal@itmo.ru

**Волковский Сергей Александрович** — кандидат технических наук, ассистент, научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57195476252](https://orcid.org/0000-0001-8462-5208), <https://orcid.org/0000-0001-8462-5208>, savolkovskii@itmo.ru

**Смирнов Даниил Сергеевич** — кандидат технических наук, ассистент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57204933153](https://orcid.org/0000-0003-4324-9327), <https://orcid.org/0000-0003-4324-9327>, dsmirnov@itmo.ru

Статья поступила в редакцию 02.02.2024  
Одобрена после рецензирования 20.07.2024  
Принята к печати 21.09.2024



Received 02.02.2024  
Approved after reviewing 20.07.2024  
Accepted 21.09.2024

Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-709-716

УДК 621.373.826

## Исследование усилительных свойств активных областей на основе $In_{0,60}Ga_{0,40}As/In_{0,53}Al_{0,20}Ga_{0,27}As$ сверхрешеток, используемых для вертикально-излучающих лазеров

Павел Евгеньевич Копытов<sup>1</sup>✉, Владислав Васильевич Андрюшкин<sup>2</sup>,

Евгений Викторович Пирогов<sup>3</sup>, Максим Сергеевич Соболев<sup>4</sup>,

Андрей Владимирович Бабичев<sup>5</sup>, Юрий Михайлович Шерняков<sup>6</sup>,

Михаил Викторович Максимов<sup>7</sup>, Андрей Владимирович Лютешкий<sup>8</sup>,

Никита Александрович Пихтин<sup>9</sup>, Леонид Яковлевич Карабинский<sup>10</sup>,

Иннокентий Игоревич Новиков<sup>11</sup>, Си-Конг Тиан<sup>12</sup>, Антон Юрьевич Егоров<sup>13</sup>

<sup>1,2,5,10,11,13</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>3,4</sup> Санкт-Петербургский национальный исследовательский Академический университет

имени Ж.И. Алфёрова РАН, Санкт-Петербург, 194021, Российская Федерация

<sup>6,7,8,9</sup> Физико-технический институт им. А.Ф. Иоффе, Санкт-Петербург, 194021, Российская Федерация

<sup>12</sup> Китайско-германский центр зеленой фотоники им. Бимберга, Чанчуньский институт оптики, точной механики и физики, Китайская академия наук, Чанчунь, 130033, Китай

<sup>1</sup> kopytovpe@itmo.ru✉, <https://orcid.org/0009-0008-8345-461X>

<sup>2</sup> vvandriushkin@itmo.ru, <https://orcid.org/0000-0002-7471-8627>

<sup>3</sup> pirogov\_evgenii@spbau.ru, <https://orcid.org/0000-0001-7186-3768>

<sup>4</sup> sobolevsms@gmail.com, <https://orcid.org/0000-0001-8629-2064>

<sup>5</sup> a.babichev@itmo.ru, <https://orcid.org/0000-0002-3463-4744>

<sup>6</sup> yuri.shernyakov@mail.ioffe.ru, <https://orcid.org/0000-0001-5574-171X>

<sup>7</sup> maximov@beam.ioffe.ru, <https://orcid.org/0000-0002-9251-226X>

<sup>8</sup> lutetskiy@mail.ioffe.ru, <https://orcid.org/0009-0007-6516-0936>

<sup>9</sup> nike@hpld.ioffe.ru, <https://orcid.org/0000-0002-0492-2227>

<sup>10</sup> lkarakchinsky@itmo.ru, <https://orcid.org/0000-0002-5634-8183>

<sup>11</sup> innokenty.novikov@itmo.ru, <https://orcid.org/0000-0003-1983-0242>

<sup>12</sup> tiansicong@ciomp.ac.cn, <https://orcid.org/0009-0001-3610-5993>

<sup>13</sup> aiegorov@itmo.ru, <https://orcid.org/0000-0002-0789-4241>

### Аннотация

**Введение.** Исследованы активные области вертикально-излучающих лазеров спектрального диапазона 1300 нм на основе сверхрешеток  $In_{0,60}Ga_{0,40}As/In_{0,53}Al_{0,20}Ga_{0,27}As$ . Проведено сопоставление пороговых характеристик лазеров с активными областями на основе сильно механически напряженных квантовых ям  $In_{0,74}Al_{0,16}Ga_{0,10}As$ .

**Метод.** Гетероструктура полосковых лазеров с  $In_{0,60}Ga_{0,40}As/In_{0,53}Al_{0,20}Ga_{0,27}As$  сверхрешеткой получена методом молекуларно-пучковой эпитаксии. Меза-структура полосковых лазеров сформирована методом селективного жидкостного травления с последующим нанесением омических контактов. Формирование полосковых лазеров с различной длиной резонатора выполнено методом ручного скальвания зеркал. Измерение выходных характеристик лазеров проведено в импульсном режиме с использованием калиброванного германиевого фотодиода большой площади, а спектральных характеристик — с помощью спектрофотометра на основе монохроматора. **Основные результаты.** Достигнутые пороговые характеристики (модальное усиление 40 см<sup>-1</sup>, плотность тока прозрачности 650 А/см<sup>2</sup>, внутренние оптические потери 8 см<sup>-1</sup>) полосковых лазеров, на основе сверхрешеток  $In_{0,60}Ga_{0,40}As/In_{0,53}Al_{0,20}Ga_{0,27}As$  с низкой степенью рассогласования кристаллической решетки слоев InGaAs сопоставимы с пороговыми характеристиками лазеров на основе активных областей с сильно механически-напряженными квантовыми ямами  $In_{0,74}Al_{0,16}Ga_{0,10}As$ . Характеристические температуры  $T_0$  и  $T_1$  составили 60 К и 87 К для полосковых лазеров с длиной резонатора 1 мм. Повышение частоты малосигнальной модуляции вертикально-излучающих лазеров и их температурной стабильности связано с использованием сильно механически-напряженных  $In_{0,74}Ga_{0,26}As/In_{0,53}Al_{0,25}Ga_{0,21}As$  сверхрешеток. **Обсуждение.** Предложенные

© Копытов П.Е., Андрюшкин В.В., Пирогов Е.В., Соболев М.С., Бабичев А.В., Шерняков Ю.М., Максимов М.В., Лютешкий А.В., Пихтин Н.А., Карабинский Л.Я., Новиков И.И., Тиан Си-Конг, Егоров А.Ю., 2024

активные области на основе InGaAs-InP сверхрешеток могут найти применение при разработке вертикально-излучающих лазеров спектрального диапазона 1300 нм. Результаты работы могут быть реализованы при создании экспериментальных образцов и оптимизации модуляционных параметров вертикально-излучающих лазеров спектрального диапазона 1300 нм.

#### **Ключевые слова**

сверхрешетка, вертикально-излучающий лазер, активная область, усиление, арсенид индия-галлия, арсенид индия-алюминия-галлия

#### **Благодарности**

Работа выполнена в рамках совместного российско-китайского проекта. Российская сторона благодарит за поддержку Министерство науки и высшего образования Российской Федерации (соглашение о предоставлении из федерального бюджета грантов в форме субсидий № 075-15-2023-579 от 11 августа 2023 года), китайская сторона — National Key R&D Program of China (2023YFE0111200).

**Ссылка для цитирования:** Копытов П.Е., Андрюшкин В.В., Пирогов Е.В., Соболев М.С., Бабичев А.В., Шерняков Ю.М., Максимов М.В., Лютецкий А.В., Пихтин Н.А., Каракинский Л.Я., Новиков И.И., Тиан Си-Конг, Егоров А.Ю. Исследование усилительных свойств активных областей на основе  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  сверхрешеток, используемых для вертикально-излучающих лазеров // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 709–716. doi: 10.17586/2226-1494-2024-24-5-709-716

## **Gain characteristics of $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$ superlattice active regions for vertical-cavity surface-emitting lasers**

**Pavel E. Kopytov<sup>1</sup>✉, Vladislav V. Andryushkin<sup>2</sup>, Evgeniy V. Pirogov<sup>3</sup>, Maxim S. Sobolev<sup>4</sup>,  
Andrey V. Babichev<sup>5</sup>, Yuri M. Shernyakov<sup>6</sup>, Mikhail V. Maximov<sup>7</sup>, Andrey V. Lyutetskiy<sup>8</sup>,  
Nikita A. Pikhtin<sup>9</sup>, Leonid Ya. Karachinsky<sup>10</sup>, Innokenty I. Novikov<sup>11</sup>,  
Sicong Tian<sup>12</sup>, Anton Yu. Egorov<sup>13</sup>**

<sup>1,2,5,10,11,13</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>3,4</sup> Alferov University, Saint Petersburg, 194021, Russian Federation

<sup>6,7,8,9</sup> Ioffe Institute, Saint Petersburg, 194021, Russian Federation

<sup>12</sup> Bimberg Chinese-German Center for Green Photonics, Changchun, 130033, China

<sup>1</sup> kopytovpe@itmo.ru✉, <https://orcid.org/0009-0008-8345-461X>

<sup>2</sup> vvandriushkin@itmo.ru, <https://orcid.org/0000-0002-7471-8627>

<sup>3</sup> pirogov\_evgenii@spbau.ru, <https://orcid.org/0000-0001-7186-3768>

<sup>4</sup> sobolevsms@gmail.com, <https://orcid.org/0000-0001-8629-2064>

<sup>5</sup> a.babichev@itmo.ru, <https://orcid.org/0000-0002-3463-4744>

<sup>6</sup> yuri.shernyakov@mail.ioffe.ru, <https://orcid.org/0000-0001-5574-171X>

<sup>7</sup> maximov@beam.ioffe.ru, <https://orcid.org/0000-0002-9251-226X>

<sup>8</sup> lutetskiy@mail.ioffe.ru, <https://orcid.org/0009-0007-6516-0936>

<sup>9</sup> nike@hpld.ioffe.ru, <https://orcid.org/0000-0002-0492-2227>

<sup>10</sup> lkarachinsky@itmo.ru, <https://orcid.org/0000-0002-5634-8183>

<sup>11</sup> innokenty.novikov@itmo.ru, <https://orcid.org/0000-0003-1983-0242>

<sup>12</sup> tiansicong@ciomp.ac.cn, <https://orcid.org/0009-0001-3610-5993>

<sup>13</sup> aiegorov@itmo.ru, <https://orcid.org/0000-0002-0789-4241>

#### **Abstract**

The results of investigation of the gain properties of 1300 nm vertical-cavity surface-emitting lasers active regions based on  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  superlattices and threshold characteristics comparison of superlattices and highly lattice mismatched  $In_{0.74}Al_{0.16}Ga_{0.10}As$  quantum wells are presented. The heterostructure of injection lasers with an  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  superlattice was grown by molecular beam epitaxy. Mesa structure of injection lasers was obtained by selective liquid etching followed by the application of ohmic contacts. The formation of injection lasers with various cavity lengths is performed using the method of manually cleaving mirrors. The output characteristics were measured in a pulsed mode using a large area calibrated germanium photodiode. Spectral characteristics were measured using a spectrophotometer based on monochromator. The achieved threshold characteristics (modal gain about  $40 \text{ cm}^{-1}$ , transparency current density about  $650 \text{ A/cm}^2$ , internal optical losses about  $8 \text{ cm}^{-1}$ ) of injection lasers based on  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  superlattices with low lattice mismatch InGaAs layers are comparable to previously presented lasers based on active regions with strongly strained  $In_{0.74}Al_{0.16}Ga_{0.10}As$  quantum wells. The characteristic temperatures  $T_0$  and  $T_1$  were 60 K and 87 K for injection lasers with a cavity length of 1 mm. An increase in the frequency of small-signal modulation of vertical-cavity surface-emitting lasers and their temperature stability is associated with the use of highly strained  $In_{0.74}Ga_{0.26}As/In_{0.53}Al_{0.25}Ga_{0.21}As$  superlattices. The proposed active regions based on InGaAs-InP superlattices have the potential to be used in the development of vertical-cavity surface-emitting lasers in the 1300 nm spectral range. The findings of this work can be applied in the realization of experimental species and optimization of modulation parameters for vertical-cavity lasers operating in the 1300 nm wavelength range.

#### **Keywords**

superlattice, vertical-cavity surface-emitting laser, active region, gain, indium gallium arsenide, indium aluminium gallium arsenide

### Acknowledgements

The results were obtained within Russian-Chinese project, with the financial support of the Russian side by the Ministry of Science and Higher Education of the Russian Federation (grant agreement in the form of a subsidy from the federal budget No. 075-15-2023-579 dated August 11, 2023) and with the financial support of the Chinese side by the National Key R&D Program of China (2023YFE0111200).

**For citation:** Kopytov P.E., Andryushkin V.V., Pirogov E.V., Sobolev M.S., Babichev A.V., Shernyakov Y.M., Maximov M.V., Lyutetskiy A.V., Pikhtin N.A., Karachinsky L.Ya., Novikov I.I., Tian Sicong, Egorov A.Yu. Gain characteristics of  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  superlattice active regions for vertical-cavity surface-emitting lasers. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 709–716 (in Russian). doi: 10.17586/2226-1494-2024-24-5-709-716

## Введение

В качестве активных областей полупроводниковых лазеров спектрального диапазона 1300 нм традиционно рассматриваются квантовые ямы InGaAsP и InAlGaAs [1], выращенные на подложках фосфида индия (InP). Несмотря на тот факт, что носители заряда в InGaAsP квантовых ямах имеют более высокую скорость излучательной рекомбинации в сравнении с InAlGaAs квантовыми ямами [1], температурная стабильность вертикально-излучающих лазеров (ВИЛ) на их основе более низкая. Значительный тепловой выброс носителей заряда, обусловленный малым разрывом зоны на гетерогранице, ограничивает температурную стабильность ВИЛ на основе InGaAsP квантовых ям [2]. Значительное изменение Оже-рекомбинации и дифференциального усиления с температурой также свойственно для системы материалов InGaAsP-InP [3].

InAlGaAs квантовые ямы традиционно используются в качестве активной области длинноволновых ВИЛ спектрального диапазона 1300–1550 нм: монолитных [4–6], гибридных [7–9], а также ВИЛ, полученных по технологии спекания пластин [10–12]. Основным недостатком применения InAlGaAs квантовых ям при формировании ВИЛ спектрального диапазона 1300 нм является высокая мольная доля алюминия (около 18 %), что в два раза превышает аналогичную величину для InAlGaAs квантовых ям спектрального диапазона 1550 нм [13, 14]. Как результат, наблюдается увеличение пороговых токов ВИЛ за счет рекомбинации Шокли–Рида–Холла [15].

Альтернативный подход при формировании ВИЛ спектрального диапазона 1300 нм состоит в использовании InGaAs-InP сверхрешеток. Из преимуществ данного подхода следует отметить: отсутствие алюминия в слоях квантовых ям, что позволяет снизить пороговые токи ВИЛ [16]; увеличение фактора оптического ограничения за счет формирования минизоны в связанных квантовых ямах, что позволяет повысить величину модального усиления [17]; снижение энергетического положения минизоны в сравнении с несвязанными InGaAs квантовыми ямами, что дает возможность увеличить температурную стабильность лазера [18].

В работе [16] реализованы высокоэффективные ВИЛ спектрального диапазона 1300 нм с активной областью на основе  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  сверхрешетки. Продемонстрирована высокая выходная оптическая мощность в одночастотном режиме генерации (около 6 мВт) и низкие внутренние оптические

потери (около 3 см<sup>-1</sup>), что свидетельствует об эффективности использования InGaAs-InP сверхрешетки в качестве активной области ВИЛ спектрального диапазона 1300 нм. Проведена оценка пороговых характеристик ВИЛ с различной величиной оптических потерь на вывод излучения. Продемонстрирована высокая величина модального усиления (30 см<sup>-1</sup>) и низкое значение плотности тока прозрачности (630 А/см<sup>2</sup>) [16]. Однако данные значения соответствуют температуре 333 К (температуре нулевого рассогласования между максимумом спектра усиления и положением резонансной длины вертикального микрорезонатора).

Цель настоящей работы — оценка усилительных свойств активных областей на основе  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  сверхрешеток при комнатной температуре (293 К), что было реализовано за счет исследования пороговых характеристик полосковых лазеров с активной областью, идентичной используемой в ВИЛ [16].

## Экспериментальные образцы и методы исследования характеристик

Для проведения эксперимента была выращена гетероструктура полосковых лазеров методом молекулярно-пучковой эпитаксии на установке Riber 49. Слой *n*-эмиттера на основе  $In_{0.52}Al_{0.48}As:Si$  толщиной 200 нм и уровнем легирования  $2 \cdot 10^{17}$  см<sup>-3</sup> сформирован на подложке из InP, легированного серой до уровня  $3 \cdot 10^{18}$  см<sup>-3</sup>. Активная область располагалась между двух волноводных слоев  $In_{0.53}Al_{0.20}Ga_{0.27}As$  толщиной 100 нм. Использование сверхрешетки на основе 25 периодов слоев  $In_{0.60}Ga_{0.40}As/In_{0.53}Al_{0.20}Ga_{0.27}As$  с толщинами 0,8 и 2 нм соответственно обеспечило фотolumинесценцию при температуре 293 К с пиком в области 1290 нм. Слой *p*-эмиттера с суммарной толщиной 1500 нм включал три слоя  $In_{0.52}Al_{0.48}As:C$  толщиной 500 нм с уровнями легирования  $1 \cdot 10^{17}$  см<sup>-3</sup>,  $5 \cdot 10^{17}$  см<sup>-3</sup> и  $1 \cdot 10^{18}$  см<sup>-3</sup> соответственно. Контактный слой  $In_{0.53}Ga_{0.47}As:C$  с толщиной 150 нм и уровнем легирования  $1 \cdot 10^{19}$  см<sup>-3</sup> образован после слоя эмиттера.

Меза-структура полоскового лазера создана методом жидкостного травления с последующим формированием омических контактов после утонения пластины. Ширина полосковых лазеров составила 400 мкм, ширина области токового контакта — 100 мкм. Полосковые лазеры с различной длиной резонатора получены методом ручного скальвания зеркал.

Измерения выходных характеристик полосковых лазеров (вольт- и ватт-амперных характеристик) про-

водились в импульсном режиме (длительность импульса 300 нс, частота повторения 4 кГц) в диапазоне температур 293–353 К. Пороговые токи и внешняя квантовая эффективность измерялись с использованием калиброванного германиевого фотодиода большой площади (диаметром 10 мм). Спектральные измерения выполнены с помощью спектрофотометра на основе монохроматора.

### Результаты и обсуждение

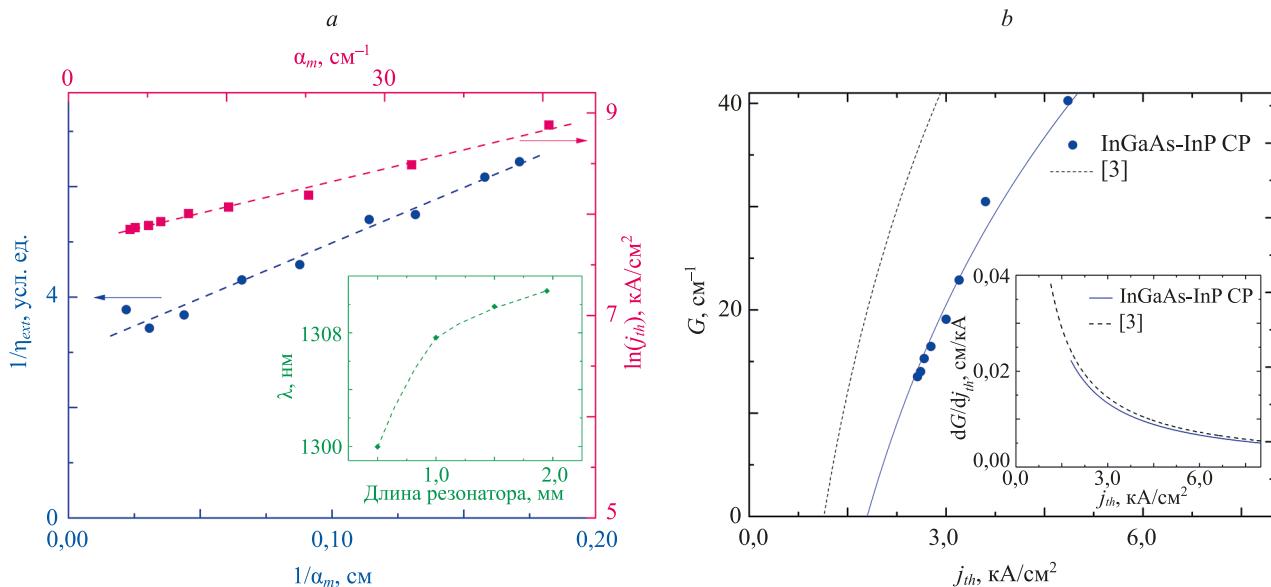
На рис. 1, *a* представлена зависимость обратной внешней квантовой эффективности лазеров ( $\eta_{ext}$ ) от обратной величины потерь на зеркалах ( $\alpha_m$ ). Величина  $\eta_{ext}$  определена с учетом спектрального положения максимума спектра многомодовой генерации (вставка к рис. 1, *a*) и полной крутизны ватт-амперной характеристики лазера. В результате вычисления получено значение  $\eta_{ext}$  для полосковых лазеров с длиной резонатора 1 мм, составившее около 21 %. Проведена аппроксимация экспериментальных данных для полосковых лазеров с различной длиной резонатора на основе выражения  $1/\eta_{ext} = (\alpha_w/\alpha_m + 1)/\eta_i$ , где  $\eta_i$  — внутренняя эффективность лазера;  $\alpha_w$  — потери в волноводе.

Определены внутренняя эффективность лазера и величина оптических потерь в волноводе, которые составили 36 % и 8 см<sup>-1</sup>. На рис. 1, *b* показана зависимость пороговой плотности тока полосковых лазеров ( $j_{th}$ ) от  $\alpha_m$ . Проведена аппроксимация экспериментальных данных

на основе выражения [16]:  $j_{th} = j_{tr}/\eta_i \cdot \exp((\alpha_w + \alpha_m)/G_m)$ , где  $G_m$  — величина модального усиления на пороге генерации;  $j_{tr}$  — плотность тока прозрачности. Определены модальное усиление и плотность тока прозрачности, которые составили 40 см<sup>-1</sup> и 650 А/см<sup>2</sup>.

В работе [3] показано, что использование сильно механически-напряженных In<sub>0,74</sub>Al<sub>0,16</sub>Ga<sub>0,10</sub>As квантовых ям (степень рассогласования квантовых ям по постоянной кристаллической решетке с материалом подложки составила 1,4 %) позволило реализовать модальное усиление около 43 см<sup>-1</sup>, величину плотности тока прозрачности на уровне 680 А/см<sup>2</sup> при величине оптических потерь в волноводе около 8 см<sup>-1</sup> [3]. На рис. 1, *b* приведено сопоставление модального усиления от уровня токовой накачки (на основе выражения  $G = G_m(\ln(\eta_i/j_{th}))$ ) для исследованных полосковых лазеров с активной областью на основе сверхрешетки с результатами, представленными в работе [3]. Сравнение полученных в настоящей работе пороговых характеристик лазеров с результатами, полученными для полосковых лазеров спектрального диапазона 1300 нм с активной областью на основе InAlGaAs–InP квантовых ям [3], показало, что использование сильно механически-напряженных InAlGaAs–InP квантовых ям позволяет повысить величину дифференциального усиления.

Проведены исследования характеристических температур  $T_0$  и  $T_1$  полосковых лазеров с длиной резонатора 1 мм в зависимости от температуры (рис. 2). Величина



*Рис. 1.* Зависимости обратной квантовой эффективности от обратных оптических потерь на зеркалах и плотности порогового тока от уровня оптических потерь на зеркалах. На вставке приведена зависимость длины волны ( $\lambda$ ) лазерной генерации в зависимости от длины резонатора (*a*). Значения модального усиления в зависимости от величины плотности порогового тока, полученные экспериментально (синие точки), с результатами аппроксимации (сплошная линия) и результатом аппроксимации для пороговых характеристик полосковых лазеров с InAlGaAs–InP квантовыми ямами [3] (пунктирная кривая). На вставке приведены значения первой производной  $G(j_{th})$  в зависимости от пороговой плотности тока (*b*)

*Fig. 1.* The dependence of the inverse quantum efficiency vs. the inverse optical losses on the mirrors, and the dependence of the threshold current density vs. the level of optical losses on the mirrors. The insert demonstrates dependance of the lasing wavelength ( $\lambda$ ) vs. cavity length (*a*). The values of the modal gain depending from the threshold current density obtained experimentally along with the approximation results (solid line). The dotted curve is the result of the approximation for the threshold characteristics of injection lasers with InAlGaAs–InP quantum wells, presented in [3]. The insert demonstrates the values of the first derivative of the  $G(j_{th})$  vs. threshold current density (*b*)

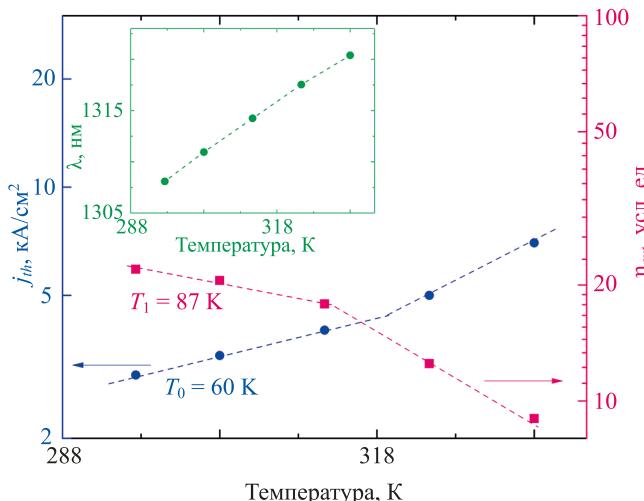


Рис. 2. Зависимость плотности порогового тока ( $j_{th}$ ) и внешней квантовой эффективности ( $\eta_{ext}$ ) полоскового лазера с длиной резонатора 1 мм от температуры. На вставке приведена зависимость длины волн лазерной генерации в зависимости от температуры

Fig. 2. Temperature dependences of the threshold current density ( $j_{th}$ ) and the external quantum efficiency ( $\eta_{ext}$ ) of an injection laser with a resonator length of 1 mm. The insert shows dependence of the lasing wavelength vs. temperature

характеристической температуры  $T_0$ , определяемая по экспоненциальному росту плотности порогового тока с температурой ( $j_{th} = j_0 \cdot \exp(T/T_0)$  [19]), составила 60 К в диапазоне температур 293–318 К. Дальнейшее повышение температуры привело к изменению наклона зависимости  $\ln(j_{th}(T))$ . Характеристическая температура  $T_1$ , определяемая по экспоненциальному спаду внешней квантовой эффективности с температурой ( $\eta_{ext} = \eta_0 \exp(-T/T_1)$  [19]), составила 87 К в диапазоне температур 293–313 К. В работе [3] показано, что для полосковых лазеров спектрального диапазона 1300 нм с активной областью на основе InAlGaAs-InP квантовых ям значения характеристических температур  $T_0$  и  $T_1$  составляют 81 К и 340 К [3].

Выполненная оценка энергетического положения минизоны в исследованной сверхрешетке на основе метода, описанного в работе [20], показала, что нижняя граница минизоны расположена на 89 мэВ, а верх-

няя — на 23 мэВ ниже положения барьера слоя  $\text{In}_{0.53}\text{Al}_{0.20}\text{Ga}_{0.27}\text{As}$ . При этом оценка положения электронных уровней для  $\text{In}_{0.74}\text{Al}_{0.16}\text{Ga}_{0.10}\text{As}$  квантовых ям толщиной 5 нм, разделенных  $\text{In}_{0.52}\text{Al}_{0.32}\text{Ga}_{0.16}\text{As}$  барьерами толщиной 10 нм [3], показывает, что в зоне проводимости наблюдается два электронных уровня, расположенных на энергетических расстояниях в 45 и 270 мэВ относительно положения барьера слоя. Таким образом, можно сделать вывод о том, что значительный тепловой выброс носителей заряда для исследованной конструкции сверхрешетки определяется меньшие значения характеристической температуры  $T_0$  в сравнении с результатами для активных областей на основе «толстых» InAlGaAs квантовых ям, в которых электронные уровни расположены на значительном удалении от положения барьера. В свою очередь, большие значения характеристической температуры  $T_1$ , продемонстрированные для InAlGaAs-InP квантовых ям, преимущественно определяются наличием дополнительных ограничивающих слоев в конструкции волновода [3], которые не используются при формировании микрорезонатора ВИЛ.

## Заключение

Проведена оценка усилительных свойств активных областей на основе  $\text{In}_{0.60}\text{Ga}_{0.40}\text{As}/\text{In}_{0.53}\text{Al}_{0.20}\text{Ga}_{0.27}\text{As}$  сверхрешеток при комнатной температуре 293 К. Показано, что использование данных сверхрешеток с низкой степенью рассогласования по постоянной кристаллической решетки слоев InGaAs (порядка 0,5 %) относительно материала подложки обеспечивает модальное усиление, плотность тока прозрачности и величину внутренних оптических потерь, сопоставимые с аналогичными пороговыми характеристиками, полученными для полосковых лазеров на основе сильно механически-напряженных  $\text{In}_{0.74}\text{Al}_{0.16}\text{Ga}_{0.10}\text{As}$  квантовых ям (степень рассогласования порядка 1,4 %) [3]. С учетом того, что частота малосигнальной модуляции вертикально-излучающих лазеров прямо пропорциональна дифференциальному усилинию, а температурная стабильность лазера определяется преимущественно надбарьерным выбросом носителей заряда, дальнейшие исследования будут направлены на создание активных областей на основе сильно механически-напряженных сверхрешеток.

## Литература

- Grasse C., Mueller M., Gruendl T., Boehm G., Roenneberg E., Wiecha P., Rosskopf J., Ortsiefer M., Meyer R., Amann M.-C. AlGaInAsPSb-based high-speed short-cavity VCSEL with single-mode emission at 1.3  $\mu\text{m}$  grown by MOVPE on InP substrate // Journal of Crystal Growth. 2016. V. 370. P. 217–220. <https://doi.org/10.1016/j.jcrysgro.2012.06.051>
- Camargo Silva M.T., Sih J.P., Chou T.M., Kirk J.K., Evans G.A., Butler J.K. 1.3  $\mu\text{m}$  strained MQW AlGaInAs and InGaAsP ridge-waveguide lasers-a comparative study // Proc. of the SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference. V. 1. 1999. P. 10–12. <https://doi.org/10.1109/IMOC.1999.867027>
- Savolainen P., Toivonen M., Orsila S., Saarinen M., Melanen P., Vilokkinen V., Dumitrescu M., Panarello T., Pessa M. AlGaInAs/InP strained-layer quantum well lasers at 1.3  $\mu\text{m}$  grown by solid source

## References

- Grasse C., Mueller M., Gruendl T., Boehm G., Roenneberg E., Wiecha P., Rosskopf J., Ortsiefer M., Meyer R., Amann M.-C. AlGaInAsPSb-based high-speed short-cavity VCSEL with single-mode emission at 1.3  $\mu\text{m}$  grown by MOVPE on InP substrate. *Journal of Crystal Growth*, 2016, vol. 370, pp. 217–220. <https://doi.org/10.1016/j.jcrysgro.2012.06.051>
- Camargo Silva M.T., Sih J.P., Chou T.M., Kirk J.K., Evans G.A., Butler J.K. 1.3  $\mu\text{m}$  strained MQW AlGaInAs and InGaAsP ridge-waveguide lasers-a comparative study. *Proc. of the SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference*. V. 1, 1999, pp. 10–12. <https://doi.org/10.1109/IMOC.1999.867027>
- Savolainen P., Toivonen M., Orsila S., Saarinen M., Melanen P., Vilokkinen V., Dumitrescu M., Panarello T., Pessa M. AlGaInAs/InP strained-layer quantum well lasers at 1.3  $\mu\text{m}$  grown by solid source

- molecular beam epitaxy // *Journal of Electronic Materials*. 1999. V. 28. N. 8. P. 980–985. <https://doi.org/10.1007/s11664-999-0208-6>
4. Park M.-R., Kwon O.-K., Han W.-S., Lee K.-H., Park S.-J., Yoo B.-S. All-epitaxial InAlGaAs-InP VCSELs in the 1.3–1.6- $\mu\text{m}$  wavelength range for CWDM band applications // *IEEE Photonics Technology Letters*. 2006. V. 18. N 16. P. 1717–1719. <https://doi.org/10.1109/LPT.2006.879940>
  5. Jewell J., Graham L., Crom M., Maranowski K., Smith J., Fanning T., Schnoes M. Commercial GaInNAs VCSELs grown by MBE // *Physica Status Solidi C*. 2008. V. 5. N 9. P. 2951–2956. <https://doi.org/10.1002/pssc.200779295>
  6. Naone R.L., Jackson A.W., Feld S.A., Galt D., Malone K.J., Hindi J.J. Monolithic GaAs-based 1.3  $\mu\text{m}$  VCSEL directly-modulated at 10 Gb/s // Proc. of the Technical Digest. Summaries of papers presented at the Conference on Lasers and Electro-Optics. Postconference Technical Digest (IEEE Cat. No.01CH37170). 2001. P. CPD13-CP1. <https://doi.org/10.1109/CLEO.2001.948231>
  7. Boehm G., Ortsiefer M., Shau R., Rosskopf J., Lauer C., Maute M., Köhler F., Mederer F., Meyer R., Amann M.-C. InP-based VCSEL technology covering the wavelength range from 1.3 to 2.0  $\mu\text{m}$  // *Journal of Crystal Growth*. 2003. V. 251. N 1-4. P. 748–753. [https://doi.org/10.1016/S0022-0248\(02\)02193-0](https://doi.org/10.1016/S0022-0248(02)02193-0)
  8. Hofmann W., Müller M., Wolf P., Mutig A., Gründl T., Böhm G., Bimberg D., Amann M.-C. 40 Gbit/s modulation of 1550 nm VCSEL // *Electronics Letters*. 2011. V. 47. N 4. P. 270–271. <https://doi.org/10.1049/el.2010.3631>
  9. Gründl T., Debernardi P., Müller M., Grasse C., Ebert P., Geiger K., Ortsiefer M., Bohm G., Meyer R., Amann M.-C. Record single-mode, high-power VCSELs by inhibition of spatial hole burning // *IEEE Journal of Selected Topics in Quantum Electronics*. 2013. V. 19. N 4. P. 1700913. <https://doi.org/10.1109/JSTQE.2013.2244572>
  10. Wolf P., Li H., Caliman A., Mereuta A., Iakovlev V., Sirbu A., Kapon E., Bimberg D. Spectral efficiency and energy efficiency of pulse-amplitude modulation using 1.3  $\mu\text{m}$  wafer-fusion VCSELs for optical interconnects // *ACS Photonics*. 2017. V. 4. N 8. P. 2018–2024. <https://doi.org/10.1021/acspophotonics.7b00403>
  11. Zhang J., Hao C., Zheng W., Bimberg D., Liu A. Demonstration of electrically injected vertical-cavity surface-emitting lasers with post-supported high-contrast gratings // *Photonics Research*. 2022. V. 10. N 5. P. 1170–1176. <https://doi.org/10.1364/PRJ.447633>
  12. Rapp S., Salomonsson F., Streubel K., Mogg S., Wenckes F., Bentell J., Hammar M. All-epitaxial single-fused 1.55  $\mu\text{m}$  vertical cavity laser based on an InP Bragg reflector // *Japanese Journal of Applied Physics*. 1999. V. 38. N 2S. P. 1261. <https://doi.org/10.1143/JJAP.38.1261>
  13. Müller M., Grasse C., Amann M.C. InP-based 1.3  $\mu\text{m}$  and 1.55  $\mu\text{m}$  short-cavity VCSELs suitable for telecom- and datacom-applications // Proc. of the 14<sup>th</sup> International Conference on Transparent Optical Networks (ICTON). 2012. P. 1–4. <https://doi.org/10.1109/icton.2012.6254394>
  14. Sirbu A., Caliman A., Mereuta A., Iakovlev V., Suruceanu G., Kapon E. Recent progress in wafer-fused VCSELs emitting in the 1550-nm band // Proc. of the 13<sup>th</sup> International Conference on Transparent Optical Networks. 2011. P. 1–4. <https://doi.org/10.1109/ICTON.2011.5970822>
  15. Novikov I.I., Nadtochiy A.M., Potapov A.Yu., Gladyshev A.G., Kolodeznyi E.S., Rochas S.S., Babichev A.V., Andryushkin V.V., Denisov D.V., Karachinsky L.Ya., Egorov A.Yu., Bougov V.E. Influence of the doping type on the temperature dependences of the photoluminescence efficiency of InGaAlAs/InGaAs/InP heterostructures // *Journal of Luminescence*. 2021. V. 239. P. 118393. <https://doi.org/10.1016/j.jlumin.2021.118393>
  16. Blokhin S.A., Babichev A.V., Gladyshev A.G., Karachinsky L.Ya., Novikov I.I., Blokhin A.A., Bobrov M.A., Maleev N.A., Andryushkin V.V., Denisov D.V., Voropaev K.O., Zhumaeva I.O., Ustinov V.M., Egorov A.Yu., Ledentsov N.N. High power single mode 1300-nm superlattice based VCSEL: Impact of the buried tunnel junction diameter on performance // *IEEE Journal of Quantum Electronics*. 2022. V. 58. N 2. P. 2400115. <https://doi.org/10.1109/JQE.2022.3141418>
  17. Каракинский Л.Я., Новиков И.И., Бабичев А.В., Гладышев А.Г., Колодезный Е.С., Рочас С.С., Курочкин А.С., Бобрецова Ю.К., Климов А.А., Денисов Д.В., Воропаев К.О., Ионов А.С., Бугров В.Е., Егоров А.Ю. Оптическое усиление в лазерных гетероструктурах с активной областью на основе короткопериодной сверхрешетки InGaAs/InGaAlAs // Оптика и спектроскопия. 2019.
  18. molecular beam epitaxy. *Journal of Electronic Materials*, 1999, vol. 28, no. 8, pp. 980–985. <https://doi.org/10.1007/s11664-999-0208-6>
  19. Park M.-R., Kwon O.-K., Han W.-S., Lee K.-H., Park S.-J., Yoo B.-S. All-epitaxial InAlGaAs-InP VCSELs in the 1.3–1.6- $\mu\text{m}$  wavelength range for CWDM band applications. *IEEE Photonics Technology Letters*, 2006, vol. 18, no. 16, pp. 1717–1719. <https://doi.org/10.1109/LPT.2006.879940>
  20. Jewell J., Graham L., Crom M., Maranowski K., Smith J., Fanning T., Schnoes M. Commercial GaInNAs VCSELs grown by MBE. *Physica Status Solidi C*, 2008, vol. 5, no. 9, pp. 2951–2956. <https://doi.org/10.1002/pssc.200779295>
  21. Naone R.L., Jackson A.W., Feld S.A., Galt D., Malone K.J., Hindi J.J. Monolithic GaAs-based 1.3  $\mu\text{m}$  VCSEL directly-modulated at 10 Gb/s. *Proc. of the Technical Digest. Summaries of papers presented at the Conference on Lasers and Electro-Optics. Postconference Technical Digest (IEEE Cat. No.01CH37170)*, 2001, pp. CPD13-CP1. <https://doi.org/10.1109/CLEO.2001.948231>
  22. Boehm G., Ortsiefer M., Shau R., Rosskopf J., Lauer C., Maute M., Köhler F., Mederer F., Meyer R., Amann M.-C. InP-based VCSEL technology covering the wavelength range from 1.3 to 2.0  $\mu\text{m}$ . *Journal of Crystal Growth*, 2003, vol. 251, no. 1-4, pp. 748–753. [https://doi.org/10.1016/S0022-0248\(02\)02193-0](https://doi.org/10.1016/S0022-0248(02)02193-0)
  23. Hofmann W., Müller M., Wolf P., Mutig A., Gründl T., Böhm G., Bimberg D., Amann M.-C. 40 Gbit/s modulation of 1550 nm VCSEL. *Electronics Letters*, 2011, vol. 47, no. 4, pp. 270–271. <https://doi.org/10.1049/el.2010.3631>
  24. Gründl T., Debernardi P., Müller M., Grasse C., Ebert P., Geiger K., Ortsiefer M., Bohm G., Meyer R., Amann M.-C. Record single-mode, high-power VCSELs by inhibition of spatial hole burning. *IEEE Journal of Selected Topics in Quantum Electronics*, 2013, vol. 19, no. 4, pp. 1700913. <https://doi.org/10.1109/JSTQE.2013.2244572>
  25. Wolf P., Li H., Caliman A., Mereuta A., Iakovlev V., Sirbu A., Kapon E., Bimberg D. Spectral efficiency and energy efficiency of pulse-amplitude modulation using 1.3  $\mu\text{m}$  wafer-fusion VCSELs for optical interconnects. *ACS Photonics*, 2017, vol. 4, no. 8, pp. 2018–2024. <https://doi.org/10.1021/acspophotonics.7b00403>
  26. Zhang J., Hao C., Zheng W., Bimberg D., Liu A. Demonstration of electrically injected vertical-cavity surface-emitting lasers with post-supported high-contrast gratings. *Photonics Research*, 2022, vol. 10, no. 5, pp. 1170–1176. <https://doi.org/10.1364/PRJ.447633>
  27. Rapp S., Salomonsson F., Streubel K., Mogg S., Wenckes F., Bentell J., Hammar M. All-epitaxial single-fused 1.55  $\mu\text{m}$  vertical cavity laser based on an InP Bragg reflector. *Japanese Journal of Applied Physics*, 1999, vol. 38, no. 2S, pp. 1261. <https://doi.org/10.1143/JJAP.38.1261>
  28. Müller M., Grasse C., Amann M.C. InP-based 1.3  $\mu\text{m}$  and 1.55  $\mu\text{m}$  short-cavity VCSELs suitable for telecom- and datacom-applications. *Proc. of the 14<sup>th</sup> International Conference on Transparent Optical Networks (ICTON)*, 2012, pp. 1–4. <https://doi.org/10.1109/icton.2012.6254394>
  29. Sirbu A., Caliman A., Mereuta A., Iakovlev V., Suruceanu G., Kapon E. Recent progress in wafer-fused VCSELs emitting in the 1550-nm band. *Proc. of the 13<sup>th</sup> International Conference on Transparent Optical Networks*, 2011, pp. 1–4. <https://doi.org/10.1109/ICTON.2011.5970822>
  30. Novikov I.I., Nadtochiy A.M., Potapov A.Yu., Gladyshev A.G., Kolodeznyi E.S., Rochas S.S., Babichev A.V., Andryushkin V.V., Denisov D.V., Karachinsky L.Ya., Egorov A.Yu., Bougov V.E. Influence of the doping type on the temperature dependences of the photoluminescence efficiency of InGaAlAs/InGaAs/InP heterostructures. *Journal of Luminescence*, 2021, vol. 239, pp. 118393. <https://doi.org/10.1016/j.jlumin.2021.118393>
  31. Blokhin S.A., Babichev A.V., Gladyshev A.G., Karachinsky L.Ya., Novikov I.I., Blokhin A.A., Bobrov M.A., Maleev N.A., Andryushkin V.V., Denisov D.V., Voropaev K.O., Zhumaeva I.O., Ustinov V.M., Egorov A.Yu., Ledentsov N.N. High power single mode 1300-nm superlattice based VCSEL: Impact of the buried tunnel junction diameter on performance. *IEEE Journal of Quantum Electronics*, 2022, vol. 58, no. 2, pp. 2400115. <https://doi.org/10.1109/JQE.2022.3141418>
  32. Каракинский Л.Я., Новиков И.И., Бабичев А.В., Гладышев А.Г., Колодезный Е.С., Рочас С.С., Курочкин А.С., Бобрецова Ю.К., Климов А.А., Денисов Д.В., Воропаев К.О., Ионов А.С., Бугров В.Е., Егоров А.Ю. Оптическое усиление в лазерных гетероструктурах с активной областью на основе короткопериодной сверхрешетки InGaAs/InGaAlAs. *Оптика и спектроскопия*, 2019.

- T. 127. № 6. С. 963–966. <https://doi.org/10.21883/OS.2019.12.48693.124-19>
18. Блохин С.А., Бабичев А.В., Гладышев А.Г., Каракинский Л.Я., Новиков И.И., Блохин А.А., Бобров М.А., Малеев Н.А., Кузьменков А.Г., Надточий А.М., Неведомский В.Н., Андрюшкин В.В., Рочас С.С., Денисов Д.В., Воропаев К.О., Жумаева И.О., Устинов В.М., Егоров А.Ю., Бугров В.Е. Исследование характеристик сверхрешетки InGaAs/InAlGaAs для вертикально-излучающих лазеров спектрального диапазона 1300 нм // Журнал технической физики. 2021. Т. 91. № 12. С. 2008–2017. <https://doi.org/10.21883/JTF.2021.12.51767.240-21>
19. Зубов Ф.И., Семенова Е.С., Кулькова И.В., Yvind K., Крыжановская Н.В., Максимов М.В., Жуков А.Е. Высокая характеристическая температура лазера на квантовых точках InAs/GaAs/InGaAsP с длиной волны излучения около 1.5 мкм, синтезированного на подложке InP // Физика и техника полупроводников. 2017. Т. 51. № 10. С. 1382–1386. <https://doi.org/10.21883/FTP.2017.10.45017.8590>
20. Dashkov A.S., Kostromin N.A., Babichev A.V., Goray L.I., Egorov A.Yu. Simulation of the energy-band structure of superlattice of quaternary alloys of diluted nitrides // Semiconductors. 2023. V. 57. N 3. P. 203–210. <https://doi.org/10.21883/sc.2023.03.56237.4163>
- and Spectroscopy, 2019, vol. 127, no. 6, pp. 1053–1056. <https://doi.org/10.1134/s0030400x19120099>
18. Blokhin S.A., Babichev A.V., Gladyshev A.G., Karachinsky L.Ya., Novikov I.I., Blokhin A.A., Bobrov M.A., Maleev N.A., Kuzmenkov A.G., Nadtochii A.M., Nevedomskiy V.N., Andryushkin V.V., Rochas S.S., Denisov D.V., Voropaev K.O., Zhumaeva I.O., Ustinov V.M., Egorov A.Yu., Bougrov V.E. Investigation of the characteristics of the InGaAs/InAlGaAs superlattice for 1300 nm range vertical-cavity surface-emitting lasers. Technical Physics, 2022, vol. 67, no. 15, pp. 2432–2440. <https://doi.org/https://doi.org/10.21883/tp.2022.15.55271.240-21>
19. Zubov F.I., Kryzhanovskaya N.V., Maximov M.V., Zhukov A.E., Semenova E.S., Kulkova I.V., Yvind K. On the high characteristic temperature of an InAs/GaAs/InGaAsP QD laser with an emission wavelength of ~1.5 μm on an InP substrate. Semiconductors, 2017, vol. 51, no. 10, pp. 1332–1336. <https://doi.org/10.1134/s1063782617100207>
20. Dashkov A.S., Kostromin N.A., Babichev A.V., Goray L.I., Egorov A.Yu. Simulation of the energy-band structure of superlattice of quaternary alloys of diluted nitrides. Semiconductors, 2023, vol. 57, no. 3, pp. 203–210. <https://doi.org/10.21883/sc.2023.03.56237.4163>

### Авторы

**Копытов Павел Евгеньевич** — инженер-исследователь, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57427541000](#), <https://orcid.org/0009-0008-8345-461X>, kopytovpe@itmo.ru

**Андрюшкин Владислав Васильевич** — кандидат технических наук, младший научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57209329441](#), <https://orcid.org/0000-0002-7471-8627>, vvandriushkin@itmo.ru

**Пирогов Евгений Викторович** — научный сотрудник, Санкт-Петербургский национальный исследовательский Академический университет имени Ж.И. Алфёрова РАН, Санкт-Петербург, 194021, Российская Федерация, [sc 24468711600](#), <https://orcid.org/0000-0001-7186-3768>, pirogov\_eugenii@spbau.ru

**Соболев Максим Сергеевич** — кандидат физико-математических наук, заведующий лабораторией, Санкт-Петербургский национальный исследовательский Академический университет имени Ж.И. Алфёрова РАН, Санкт-Петербург, 194021, Российская Федерация, [sc 57205203666](#), <https://orcid.org/0000-0001-8629-2064>, sobolevsm@gmail.com

**Бабичев Андрей Владимирович** — кандидат физико-математических наук, старший научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 56819964000](#), <https://orcid.org/0000-0002-3463-4744>, a.babichev@itmo.ru

**Шерняков Юрий Михайлович** — кандидат физико-математических наук, старший научный сотрудник, Физико-технический институт им. А.Ф. Иоффе, Санкт-Петербург, 194021, Российская Федерация, [sc 7005153098](#), <https://orcid.org/0000-0001-5574-171X>, Yuri.Shernyakov@mail.ioffe.ru

**Максимов Михаил Викторович** — доктор физико-математических наук, заведующий лабораторией, Физико-технический институт им. А.Ф. Иоффе, Санкт-Петербург, 194021, Российская Федерация, [sc 7004999626](#), <https://orcid.org/0000-0002-9251-226X>, maximov@beam.ioffe.ru

**Лютеский Андрей Владимирович** — кандидат физико-математических наук, ведущий научный сотрудник, Физико-технический институт им. А.Ф. Иоффе, Санкт-Петербург, 194021, Российская Федерация, [sc 6506787947](#), <https://orcid.org/0009-0007-6516-0936>, lutetskiy@mail.ioffe.ru

**Пихтин Никита Александрович** — кандидат физико-математических наук, заведующий лабораторией, Физико-технический институт им. А.Ф. Иоффе, Санкт-Петербург, 194021, Российская Федерация, [sc 7004717756](#), <https://orcid.org/0000-0002-0492-2227>, nikitahpld.ioffe.ru

**Каракинский Леонид Яковлевич** — доктор технических наук, ведущий научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 6603558355](#), <https://orcid.org/0000-0002-5634-8183>, lkarakinsky@itmo.ru

**Новиков Иннокентий Игоревич** — кандидат физико-математических наук, старший научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 7202658480](#), <https://orcid.org/0000-0003-1983-0242>, innokenty.novikov@itmo.ru

### Authors

**Pavel E. Kopytov** — Engineer-Researcher, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57427541000](#), <https://orcid.org/0009-0008-8345-461X>, kopytovpe@itmo.ru

**Vladislav V. Andriushkin** — PhD, Junior Researcher, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57209329441](#), <https://orcid.org/0000-0002-7471-8627>, vvandriushkin@itmo.ru

**Evgeniy V. Pirogov** — Scientific Researcher, Alferov Academic University, Saint Petersburg, 194021, Russian Federation, [sc 24468711600](#), <https://orcid.org/0000-0001-7186-3768>, pirogov\_eugenii@spbau.ru

**Maxim S. Sobolev** — PhD (Physics & Mathematics), Head of Laboratory, Alferov Academic University, Saint Petersburg, 194021, Russian Federation, [sc 57205203666](#), <https://orcid.org/0000-0001-8629-2064>, sobolevsm@gmail.com

**Andrey V. Babichev** — PhD (Physics & Mathematics), Senior Researcher, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 56819964000](#), <https://orcid.org/0000-0002-3463-4744>, a.babichev@itmo.ru

**Yuri M. Shernyakov** — PhD (Physics & Mathematics), Senior Researcher, Ioffe Institute, Saint Petersburg, 194021, Russian Federation, [sc 7005153098](#), <https://orcid.org/0000-0001-5574-171X>, Yuri.Shernyakov@mail.ioffe.ru

**Mikhail V. Maximov** — D.Sc. (Physics & Mathematics), Head of Laboratory, Ioffe Institute, Saint Petersburg, 194021, Russian Federation, [sc 7004999626](#), <https://orcid.org/0000-0002-9251-226X>, maximov@beam.ioffe.ru

**Andrey V. Lyutetskiy** — PhD (Physics & Mathematics), Leading Researcher, Ioffe Institute, Saint Petersburg, 194021, Russian Federation, [sc 6506787947](#), <https://orcid.org/0009-0007-6516-0936>, lutetskiy@mail.ioffe.ru

**Nikita A. Pikhtin** — PhD, Head of Laboratory, Ioffe Institute, Saint Petersburg, 194021, Russian Federation, [sc 7004717756](#), <https://orcid.org/0000-0002-0492-2227>, nikitahpld.ioffe.ru

**Leonid Ya. Karachinsky** — D.Sc., Leading Researcher, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 6603558355](#), <https://orcid.org/0000-0002-5634-8183>, lkarakinsky@itmo.ru

**Innokenty I. Novikov** — PhD (Physics & Mathematics), Senior researcher, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 7202658480](#), <https://orcid.org/0000-0003-1983-0242>, innokenty.novikov@itmo.ru

**Тиан Си-Конг** — PhD, директор по производству, Китайско-германский центр зеленой фотоники им. Бимберга, Чанчуньский институт оптики, точной механики и физики, Китайская академия наук, Чанчунь, 130033, Китай, [sc 56978639900](#), <https://orcid.org/0009-0001-3610-5993>, [tiansicong@ciomp.ac.cn](mailto:tiansicong@ciomp.ac.cn)

**Егоров Антон Юрьевич** — доктор физико-математических наук, профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 7202362169](#), <https://orcid.org/0000-0002-0789-4241>, [aiegorov@itmo.ru](mailto:aiegorov@itmo.ru)

Статья поступила в редакцию 23.06.2024  
Одобрена после рецензирования 02.08.2024  
Принята к печати 16.09.2024

**Sicong Tian** — PhD, Head of Laser Fabrication, Bimberg Chinese-German Center for Green Photonics, Changchun, 130033, China, [sc 56978639900](#), <https://orcid.org/0009-0001-3610-5993>, [tiansicong@ciomp.ac.cn](mailto:tiansicong@ciomp.ac.cn)

**Anton Yu. Egorov** — D.Sc. (Physics & Mathematics), Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 7202362169](#), <https://orcid.org/0000-0002-0789-4241>, [aiegorov@itmo.ru](mailto:aiegorov@itmo.ru)

Received 23.06.2024  
Approved after reviewing 02.08.2024  
Accepted 16.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-717-725

УДК 535.67

## Изменение оптических свойств поверхности серебра за счет лазерного структурирования

Анастасия Алексеевна Морозова<sup>1</sup>, Ульяна Александровна Капустина<sup>2</sup>,  
Дарья Сергеевна Лутошина<sup>3</sup>, Галина Викторовна Романова<sup>4</sup>

<sup>1,2,3,4</sup> Университет ИТМО, Санкт-Петербург, 197101, Российской Федерации

<sup>1</sup> [aamorozova@itmo.ru](mailto:aamorozova@itmo.ru), <https://orcid.org/0000-0003-2329-1288>

<sup>2</sup> [kapustinaulya@yandex.ru](mailto:kapustinaulya@yandex.ru), <https://orcid.org/0009-0001-8520-5579>

<sup>3</sup> [ld3282@itmo.ru](mailto:ld3282@itmo.ru), <https://orcid.org/0000-0003-3741-5819>

<sup>4</sup> [gvromanova@itmo.ru](mailto:gvromanova@itmo.ru), <https://orcid.org/0000-0001-9581-4290>

### Аннотация

**Введение.** Одной из главных задач ювелирной промышленности является приданье эстетичного и художественного вида изделию. Это может достигаться путем изменения его цвета. Перспективным способом окрашивания драгоценных металлов является одноэтапный лазерный метод формированияnanoструктур с плазмонными свойствами. Однако сегодня остается нерешенной проблема недостаточного понимания механизма формирования цветных покрытий. Поверхностные структуры обычно рассматриваются как набор отдельных сферических наночастиц. Для полного понимания происходящих физико-химических процессов необходимо рассматривать наночастицы в совокупности как агломераты наночастиц на поверхности. **Методы и материалы.** Для исследования выбран плоскопараллельный образец серебра 999,9 ювелирной пробы. Обработка поверхности серебра проводилась с помощью лазерного комплекса на базе иттербийового волоконного лазера (ООО «Лазерный Центр», Санкт-Петербург, Россия) с наносекундной длительностью импульсов методом построчного сканирования по одной и двум осям сфокусированным лазерным пучком диаметром  $d_0 = 50$  мкм. Для характеристизации поверхности серебра до и после лазерного воздействия использованы оптическая и сканирующая электронная микроскопия. **Основные результаты.** Исследовано влияние энергии в импульсе и частоты следования импульсов на оптические свойства поверхности серебра. Продемонстрирован процесс генерирования лазерно-модифицированных поверхностных nanoструктур, характер их изменения при переходе от сканирования по одной оси к построчному сканированию. Показано, что изменение рельефа поверхности наблюдается и вне непосредственной зоны обработки. Отмечено неравномерное распределение nanoструктурных элементов по поверхности обрабатываемой области, что приводит к неравномерности наблюдаемого цвета поверхности на микроуровне. **Обсуждение.** На основании анализа полученных данных предложена гипотеза формирования nanoструктур. При воздействии лазерного излучения на поверхности серебра изначально формируются отдельные наночастицы шарообразной формы. Далее при увеличении температуры концентрация наночастиц значительно возрастает, что приводит к их слиянию и образованию из агломерированных наночастиц некоторых кластеров неправильной формы. Полученные новые данные о процессе формирования поверхностных nanoструктур позволяют расширить понимание происходящих процессов, а также показывают возможность применения метода прямого лазерного окрашивания серебра в ювелирной промышленности.

### Ключевые слова

лазерное окрашивание, плазмонные наночастицы серебра, лазерная модификация, оптические характеристики, морфология поверхности

### Благодарности

Работа выполнена при поддержке программы «Приоритет 2030».

**Ссылка для цитирования:** Морозова А.А., Капустина У.А., Лутошина Д.С., Романова Г.В. Изменение оптических свойств поверхности серебра за счет лазерного структурирования // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 717–725. doi: 10.17586/2226-1494-2024-24-5-717-725

## Change of optical properties of silver surface due to laser structuring

Anastasia A. Morozova<sup>1</sup>, Ulyana A. Kapustina<sup>2</sup>, Daria S. Lutoshina<sup>3</sup>, Galina V. Romanova<sup>4</sup>

<sup>1,2,3,4</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>1</sup> aamorozova@itmo.ru, <https://orcid.org/0000-0003-2329-1288>

<sup>2</sup> kapustinaulya@yandex.ru, <https://orcid.org/0009-0001-8520-5579>

<sup>3</sup> ld3282@itmo.ru, <https://orcid.org/0000-0003-3741-5819>

<sup>4</sup> gvromanova@itmo.ru, <https://orcid.org/0000-0001-9581-4290>

### Abstract

One of the main goals of jewelry is to give the product an aesthetic and artistic look. This can be achieved by changing its color. The promising methods of precious metal coloration is a one-step laser method of forming nanostructures with plasmonic properties. However, the lack of understanding of the mechanism of formation of color coatings remains an unresolved problem today. Surface structures are usually considered as a set of individual spherical nanoparticles. But to fully understand the physicochemical processes taking place, it is necessary to consider nanoparticles in aggregate as agglomerates of these nanoparticles on the surface. The silver samples of 99.99 % purity were selected for the study. Laser exposure was carried out in air using a system based on an ytterbium fiber laser with nanosecond pulse duration. The silver surface was processed by line-by-line scanning along one and two axes with a focused laser beam with the diameter  $d_0 = 50 \mu\text{m}$ . Optical and scanning electron microscopy were used to characterize the silver surface before and after laser treatment. In this work, the effect of some laser exposure parameters, such as laser pulse energy and pulse repetition rate, on the optical properties of silver surface were investigated. The focus of this work is on generated laser-modified surface nanostructures and the character of their change when going from single axis scanning to line scanning. It is shown that surface topography changes are also observed in the region outside the immediate treatment zone. The uneven distribution of nanostructural elements on the surface of the treated area is registered, which causes the irregularity of the observed surface color at the microlevel. Based on the analysis of the obtained data, a hypothesis of nanostructure formation is proposed. Under laser exposure, individual spherical-shaped nanoparticles are initially formed on the silver surface. Then with increasing temperature their concentration increases significantly. This leads to their adhesion and formation of irregularly shaped clusters of aggregated nanoparticles. The obtained new data on the process of formation of surface nanostructures allow us to expand the understanding of the ongoing processes, as well as to approach the integration of the method of direct laser coloring of silver in the jewelry industry.

### Keywords

laser coloration, plasmonic silver nanoparticles, laser modification, optical characteristics, surface morphology

### Acknowledgements

This research was supported by the Priority 2030 Federal Academic Leadership Program.

**For citation:** Morozova A.A., Kapustina U.A., Lutoshina D.S., Romanova G.V. Change of optical properties of silver surface due to laser structuring. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 717–725 (in Russian). doi: 10.17586/2226-1494-2024-24-5-717-725

### Введение

Формированиеnanoструктур с плазмонными свойствами на поверхности драгоценных металлов является перспективным методом их окрашивания. Сравнение различных подходов к изменению цвета поверхности металлов по пяти ключевым параметрам (яркость цвета, независимость от угла наклона, долговечность, технологичность и достижимое пространственное разрешение) показывает, что подход, реализованный за счет использования плазмонных свойств поверхностных nanoструктур, при достаточной устойчивости, способен составить конкуренцию существующим методам окрашивания на основе пигментов [1].

Изменение цвета поверхности драгоценных металлов путем использования плазмонных эффектов представлено в научных работах [2]. Методы изготовления цветных покрытий также вариативны: лазерная интерференционная литография [3], электронно-лучевая литография [4], ионно-лучевая литография [5], литография наноимпринта [3] и др. Использование таких методов является сложной задачей, так как требует много времени и подразумевает многоэтапную обработку.

Известен одноэтапный способ получения nanoструктур на металлических поверхностях с целью окрашивания с помощью лазерного излучения пикосекундной длительности импульсов [6, 7]. Недостатком этой технологии является сложность ее внедрения в промышленность ввиду высокой стоимости используемого лазера пикосекундной длительности импульсов, что несовоимственно с требованиями недорогого массового производства.

В работах [8, 9] показан одноэтапный метод создания цветных покрытий из наночастиц с плазмонными свойствами с использованием лазерного источника пикосекундной длительности импульсов, который является более промышленно доступным. Исследования показывают, что пикосекундный лазерный источник способен составить конкуренцию источникам с ультракороткой длительностью импульса.

Понимание механизма формирования цвета — важный аспект изучения данной технологии. После лазерного воздействия на поверхности наблюдаются хаотически расположенные наночастицы различного размера. Считается, что образование этих наночастиц происходит в результате сочетания тепловых эффектов и повторного осаждения частиц после лазерной абляции [10, 11]. Плазмонный эффект упоминается как механизм, лежащий в основе получения цвета [6, 12].

Ранее в исследованиях по изучению механизмов формирования цвета поверхности структуры рассматривались как отдельные сферические наночастицы,

однако для полного понимания происходящих процессов необходимо рассматривать их в совокупности, так как на поверхности образуются агломераты этих наночастиц.

Также необходимо определить влияние параметров лазерного воздействия на оптические свойства поверхности серебра (Ag) и соотнести регистрируемые изменения с модификацией морфологии поверхности. Данное исследование способно приблизить рассматриваемую технологию к интегрированию в ювелирную промышленность.

### Материалы и методы

В настоящей работе выбран плоскопараллельный образец Ag 999,9 ювелирной пробы размером  $3,5 \times 2$  мм и толщиной 7,8 мм. Использование металла без примесей легирующих элементов позволяет исключить вклад легирующих добавок, например меди, которая активнее вступает в реакцию окисления при взаимодействии с лазерным излучением в воздушной среде.

Лазерная обработка поверхности Ag с целью формирования на его поверхностиnanoструктур с плазмонными свойствами проводилась с помощью лазерного комплекса «Минимаркер-2» (ООО «Лазерный центр», Санкт-Петербург, Россия) на базе импульсного иттербийевого волоконного лазера. Выбор лазерного источника обуславливается достаточным поглощением выбранного металла для рабочей длины волны лазера, а также коммерческой доступностью установки в сравнении с пико- и фемтосекундными лазерными источниками. Обработка поверхности Ag производилась методом построчного сканирования по одной (единичные линии) и двум осям (квадратные области) сфокусированным лазерным пучком с диаметром  $d_0 = 50$  мкм. Таким образом, были созданы единичные линии при использовании режимов лазерного воздействия с вариативными значениями энергии в импульсе от 0,096 до 0,92 мДж при фиксированном значении скорости перемещения лазерного пучка. Области, полученные с помощью сканирования по двум осям, образованы путем вариации частоты следования импульсов при фиксированном значении энергии в импульсе 0,1 мДж и расстоянии между импульсами 20 мкм.

Для детектирования измененной поверхности использовался оптический микроскоп Zeiss Axio Imager A1M в режиме отражения. С помощью микроскопа-спектрофотометра ЛОМО МСФУ-К и спектрофотометра СФ-56 были получены спектры отражения модифицированных поверхностей Ag на микро- и макроуровнях в диапазоне 360–900 нм. Изучение морфологии и элементного составов nanoструктурированных поверхностей проводилось с помощью сканирующего электронного микроскопа (СЭМ) Zeiss Merlin.

### Лазерный синтез плазмонных nanoструктур при сканировании по одной координатной оси

Рассматриваемый метод прямого лазерного окрашивания Ag основывается на нагреве поверхности

металла выше температуры кипения. Под действием гидродинамических сил и давления паров испарения поверхность материала деформируется. Также испаряемый материал в виде молекул, атомов и ионов разлетается за пределы зоны обработки, при этом часть молекул в результате конденсации осаждается в виде наночастиц, формируя нанорельеф поверхности. В данном исследовании наибольший интерес представляет именно нанорельеф, который может обладать плазмонными свойствами.

Явление плазмонного резонанса основывается на том, что взаимодействие света определенной длины волн с металлической наночастицей на границе раздела между металлом и диэлектриком вызывает коллективное возбуждение электронов проводимости в металлических nanoструктурах. В результате этого формируется узкий пик отражения в видимом спектре, что обуславливает образование цвета. Плазмонными свойствами обладают сферические наночастицы размерами до 100 нм [13, 14].

Первично для анализа выбраны режимы лазерного воздействия, обеспечивающие сканирование лазерного пучка по одной координатной оси. Это позволило получить дополнительные данные о процессе синтеза для последующей корреляции результатов с данными после сканирования по двум осям. Экспериментально подобраны режимы лазерного воздействия, которые обеспечивают инициацию процесса лазерного синтеза в разной степени.

Режим 1. Начальный процесс изменения цвета поверхности на микроуровне (рис. 1, a).

Режим 2. Активный синтез наночастиц (рис. 1, c).

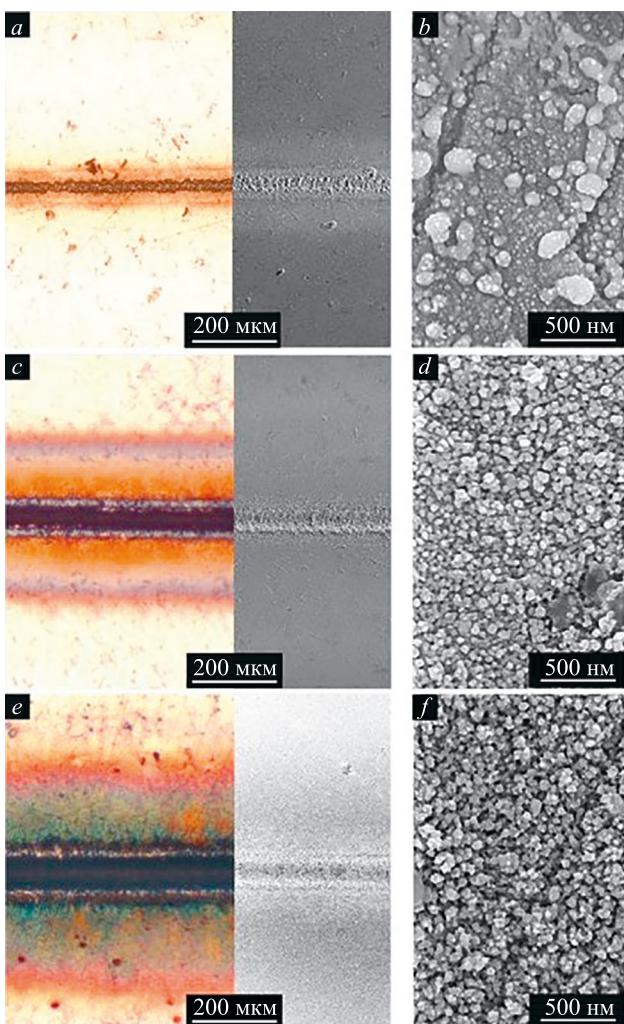
Режим 3. Перегрев обрабатываемой поверхности с образованием сильно поглощающих структур (рис. 1, e).

Для выбранных режимов получены микрофотографии поверхности Ag после лазерного воздействия и СЭМ-снимки его поверхности (рис. 1).

Визуально изменение цвета поверхности Ag и контраста на СЭМ-снимках сформированных канавок свидетельствует об изменении рельефа поверхности в области за пределами зоны обработки и позволяет определить радиус разлета наночастиц. Так, для режима 1 разлет составил приблизительно 140 мкм, для режима 2 — 370 мкм, для режима 3 — 730 мкм. СЭМ-снимки областей, полученных на расстоянии 30–100 мкм от края канавки (рис. 1, b, d, f), также подтверждают изменение рельефа за счет формирования на поверхности Ag nanoструктур.

Наибольший интерес для изучения представляют режим 2, так как он позволяет определить физические и химические изменения поверхности Ag в результате лазерной обработки, необходимые для понимания механизма образования цвета. Визуально зону воздействия можно охарактеризовать тремя областями (рис. 2): область 1 (канавка) непосредственного лазерного воздействия; область 2 — контрастная область сразу за пределами канавки и области 3–8 — с градиентным изменением цвета.

Для выбранных областей получены СЭМ-снимки поверхности (рис. 3). По данным СЭМ-снимков в об-



*Рис. 1.* Микрофотографии и СЭМ-снимки поверхности серебра после лазерного воздействия для значений энергии в импульсе: 0,096 мДж (а, б); 0,26 мДж (с, д); 0,92 мДж (е, ж)

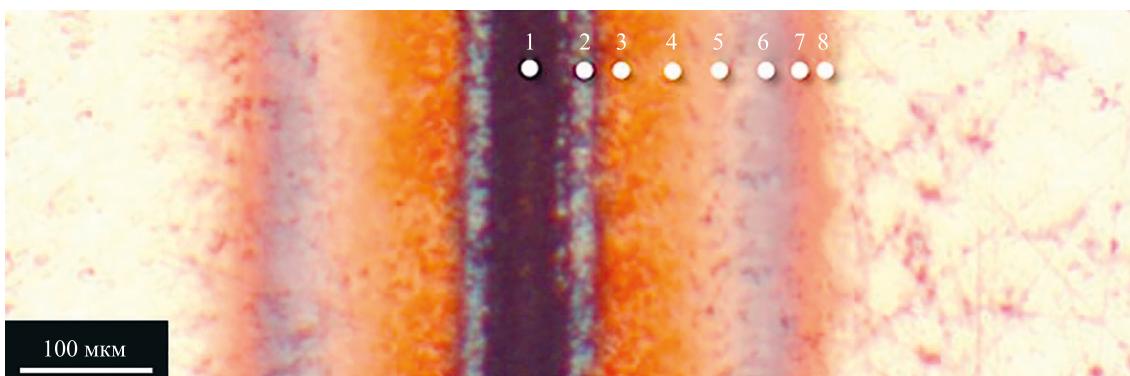
*Fig. 1. Micrographs and SEM images of the silver surface after laser exposure for pulse energy values: 0.096 mJ (a, b); 0.26 mJ (c, d); 0.92 mJ (e, f)*

ласти 1 наблюдается рельеф, представляющий собой результат движения масс расплава Ag при лазерном нагреве. Элементы расплава равномерно покрыты на-

ноструктурными элементами. В области 2 морфология сформирована застывшими каплями аблируемого материала, которые также равномерно покрытыnanoструктурными элементами. Области 3–8 представляют собой nanostructuredированную поверхность, состоящую из агломерированных наночастиц. В области 3 средний размер агломерата наночастиц меньшего размера составляет 50 нм. Размер структур, сформированных в результате агломерации наночастиц, уменьшается к области 5. От области 6 к области 8 заметно уменьшается размер наночастиц, а также их концентрация. Снимок для необработанного Ag был сделан для области на расстоянии 500 мкм от края канавки. На поверхности присутствуют единичные элементы частиц с размерами до 5 нм, что свидетельствует о том, что фактический разлет частиц превышает 350 мкм, однако, данные частицы не обладают необходимыми размерами и концентрацией для выраженного эффекта плазмонного резонанса.

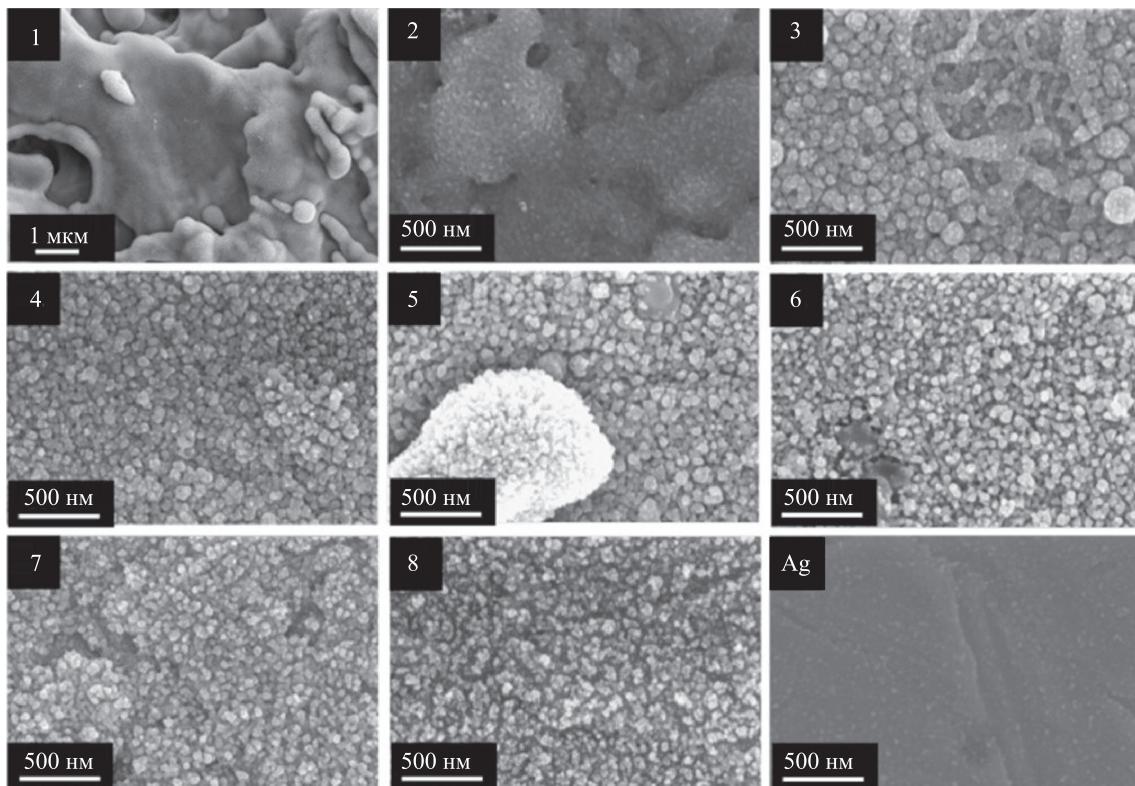
Для исследуемых областей получены спектры отражения (рис. 4). Коэффициент отражения для модифицированной области во всех случаях ниже коэффициента отражения необработанной поверхности Ag, что является следствием снижения отражательной способности подложки с nanoструктурой.

Спектр, соответствующий области 1, является наименее выраженным и пологим — nanoструктура сильно поглощает свет в видимой части излучения. Это может быть связано с неровностями поверхности, которые образуются в результате движений расплава и частично поглощают падающий свет. Область 2 имеет минимум спектра отражения на длинах волн 750–760 нм. Пик спектра отражения находится в области 500–550 нм. Средний размер структурных элементов для данной области составляет 30 нм. Для областей 3–5 пик спектра отражения находится в области 750–800 нм. Общей тенденцией является сужение области поглощения от 550 нм к 400 нм, что может быть связано с уменьшением размеров кластеров из маленьких наночастиц и, соответственно, смещению спектра к ультрафиолетовой области. Спектр области 6 демонстрирует широкий пик отражения, что может являться промежуточным этапом перед формированием второго пика отражения, которые наблюдаются для областей 7 и 8.

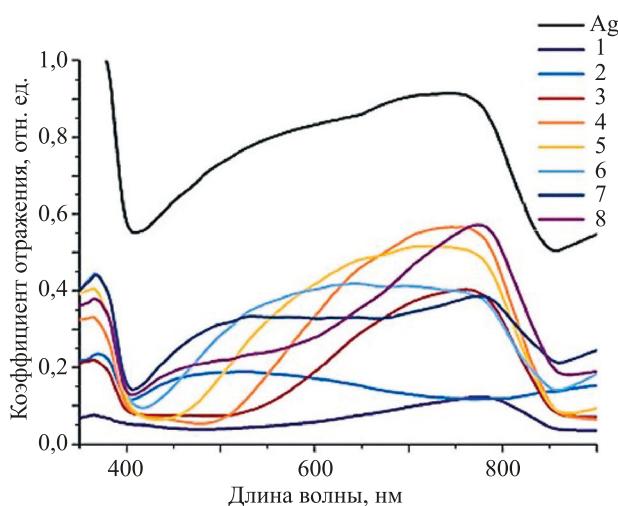


*Рис. 2.* Микрофотография поверхности серебра с обозначением условных зон, полученных в результате лазерного воздействия

*Fig. 2. Microphotograph of silver surface showing designated zones resulting from laser exposure*



*Rис. 3. СЭМ-снимки областей 1–8, а также немодифицированной поверхности серебра (Ag) после лазерной обработки*  
*Fig. 3. SEM images of regions 1–8 as well as unmodified silver (Ag) surface after laser exposure*



*Рис. 4. Спектры отражения областей 1–8 после лазерного воздействия и немодифицированной поверхности серебра (Ag). Области, с которых были сняты спектры, указаны на рис. 2*

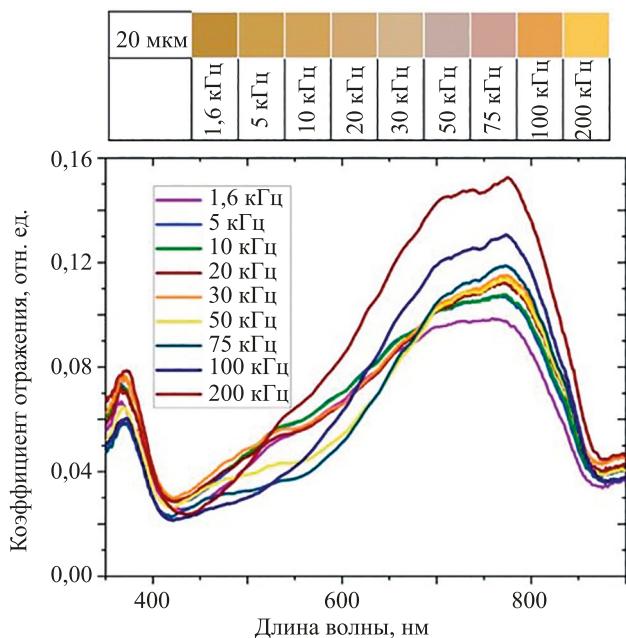
*Fig. 4. Reflectance spectra of regions 1–8 after laser exposure and the unmodified silver surface. The regions from which the spectra were taken are indicated in Fig. 2*

Пик плазмонного резонанса для одиночных наночастиц Ag находится в диапазоне от 400 до 530 нм в зависимости от размера частицы [13], что частично совпадает с полученными результатами.

#### Лазерный синтез плазмонныхnanoструктур при сканировании по двум координатным осям

С точки зрения использования рассматриваемого метода окрашивания в декоративных целях интерес представляют не отдельные линейные элементы, а изображения и рисунки, которые реализуются методом построчного сканирования. Использование сканирования по двум осям изменяет характер распределения наночастиц на поверхности Ag. Как было отмечено в разделе «Лазерный синтез плазмонных nanoструктур при сканировании по одной координатной оси», зона разлета наночастиц может быть на порядок больше диаметра лазерного пятна. При построчном сканировании на модифицируемую область могут влиять последующие записываемые линии, так как при наложении наночастицы агрегируются, слипаются, образуя новые электронные связи. Распределение формируемых nanoструктур напрямую влияет на результирующий цвет модифицированной поверхности.

Изменения цвета поверхности можно добиться путем вариации различных параметров лазерного воздействия. Частота следования импульсов имеет большое значение при обработке поверхности лазерным излучением, поскольку контролирует пропускную способность, выходную энергию и время доставки [15]. Также известно, что использование излучения большей частоты приводит к повышению температуры, что существенно влияет на характер деформации поверхности. Соответственно, данный параметр является ключевым в исследовании влияния параметров лазера на прямое лазерное окрашивание Ag.



*Rис. 5. Спектры отражения модифицированной поверхности серебра при вариативных значениях частоты повторения импульсов*

*Fig. 5. Surface reflectance spectra of the modified silver surface at varying values of the pulse repetition rates*

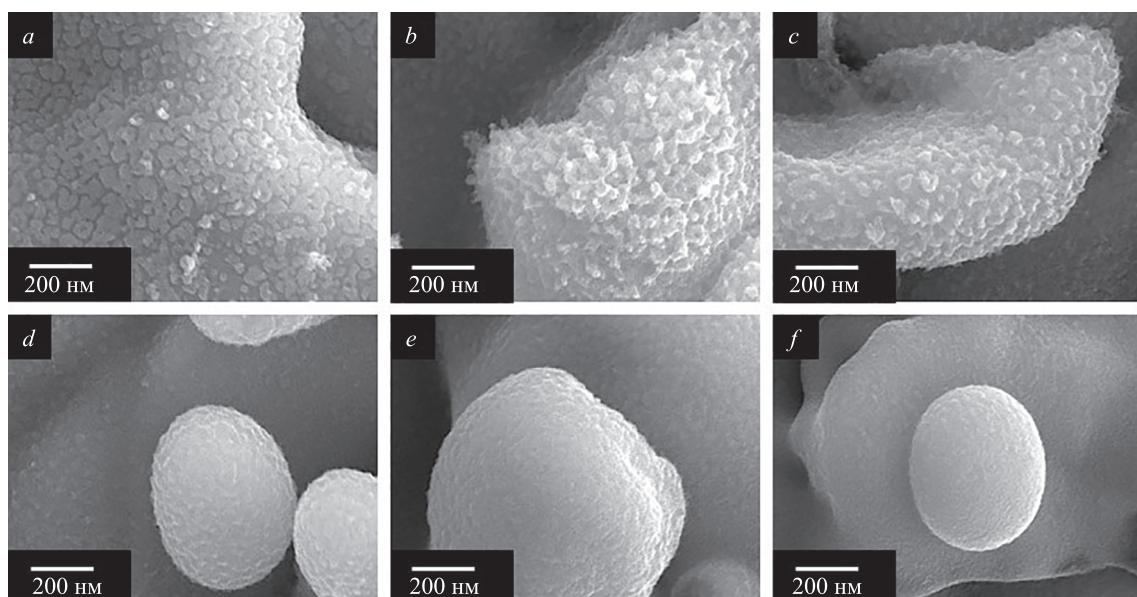
Для анализа зависимостей записан массив из квадратов со стороной 1 мм с одинаковым значением энергии в импульсе 0,1 мДж при различной частоте следования импульсов. Для исследования выбраны режимы лазерного воздействия, которые обеспечивают одинаковое значение расстояния между импульсами. Спектры отражения с полученных цветных областей,

а также визуально наблюдаемый цвет поверхности представлены на рис. 5.

В данном случае также наблюдается формирование дополнительного пика поглощения, который имеет менее выраженный характер. Это обосновывается спецификой резонанса электронных колебаний. Пик резонанса связанный системой находится в диапазоне длин волн с большим значением, что приводит к регистрации дополнительных пиков в области, смещенной к инфракрасному диапазону [15]. Можно сделать вывод, что на оптические свойства влияет совокупный набор наночастиц и формируемых из нихnanoструктур. Пики отражения при увеличении частоты следования импульсов также смещаются в инфракрасную область с одновременным увеличением отражательной способности подложки.

Стоит отметить, что плазмонный резонанс чувствителен к углу, образующемуся между связанными с поверхностью наночастицами и подложкой [16]. Наблюданное изменение цвета при фиксированном значении энергии и вариативной частоте следования импульсов предполагает сильную временную зависимость формирования цвета. Обработка материалов с использованием более высокой частоты повторения лазерного излучения приводит к повышению температуры из-за кумулятивного нагрева. Таким образом, совокупный нагрев поверхности может повлиять на контактный угол формируемых nanoструктур, находящихся на подложке.

С ростом частоты повторения импульсов увеличивается температура, постепенно происходит переплав поверхности, что приводит к появлению локальных неровностей. На поверхности этих неровностей находятся nanoструктуры, сформированные в результате агрегации разлетающихся в процессе абляции наноча-



*Рис. 6. СЭМ-снимки поверхности серебра после воздействия лазерным излучением с фиксированным значением энергии 0,1 мДж и вариативных значениях частоты следования импульсов: 1,6 кГц (a); 10 кГц (b); 30 кГц (c); 50 кГц (d); 100 кГц (e); 200 кГц (f)*

*Fig. 6. SEM images of the silver surface after laser exposure with a fixed energy value 0.1 mJ and variable values of pulse repetition frequency: 1.6 kHz (a); 10 kHz (b); 30 kHz (c); 50 kHz (d); 100 kHz (e), 200 kHz (f)*

стиц. С увеличением частоты следования импульсов лазерного излучения, а соответственно, и температуры наноструктуры сначала кластеризуются отдельными группами частиц, а затем в процессе лазерной абляции начинают налипать друг на друга, что приводит к практически однородному распределению наноструктур по поверхности (рис. 6). Оценить распределение и размеры наноструктур достаточно сложно, так как возникает вопрос: а что именно является единичным структурным элементом?

Для получения дополнительных сведений был выбран режим лазерного воздействия, соответствующий незначительному изменению цвета поверхности. Используемое значение энергии в импульсе соответствует 0,04 мДж, расстояние между импульсами равно 50 мкм, т. е. лазерная запись происходила без перекрытия по обеим осям (рис. 7).

Исследование полученных СЭМ-снимков показало, что на поверхности Ag образуются частицы практически правильной сферической формы преимущественно размером до 100 нм. Такие частицы могут обладать свойством поверхностного плазмонного резонанса [13], однако их концентрации недостаточно для видимых изменений оптических свойств поверхности.

Таким образом, при воздействии лазерного излучения на поверхности Ag изначально формируются отдельные наночастицы шарообразной формы. Далее при увеличении температуры их концентрация значительно возрастает, что приводит к их слипанию и образованию из агломерировавших наночастиц некоторых кластеров

неправильной формы. Можно заметить, что в зависимости от рельефных особенностей образующиеся блоки имеют различный вид — на выступающих частях поверхности, образованных застывшими выплавами материала, происходит более плотное хаотичное спекание. Таким образом, наноструктурные элементы распределяются по поверхности металла неравномерно, что вероятно приводит к неравномерности конечного наблюдаемого микроцвета.

### Заключение

В результате проведенных исследований выявлено, что после лазерного воздействия на серебро при режимах, позволяющих достигнуть температур выше температуры кипения материала, на поверхность осаждаются наночастицы разного размера, которые в результате агрегирования образуют поверхностную наноструктуру. Изменения рельефа поверхности наблюдаются и в области за пределами зоны обработки. Таким образом, при модификации поверхности путем сканирования по двум осям, на формируемый нанорельеф также влияют осаждаемые частицы из последующих линий сканирования, если расстояние между ними меньше зоны разлета.

Выполнено сравнение морфологии поверхности при сканировании по одной и двум координатным осям и определена взаимосвязь между формируемой морфологией и методом сканирования. Равномерные наноструктуры, отмеченные в областях 1 и 2 для единичных треков, наблюдаются во впадинах рельефа поверхности, обработанной при сканировании по двум осям. Хаотически расположенные наноструктуры в виде агломерированных наночастиц, соответствующие областям 3–8, преимущественно наблюдаются на выступающих частях поверхности. Данное распределение наноструктур может быть результатом наложения области с градиентным изменением цвета (области 3–8) на область непосредственного лазерного воздействия. Можно предположить, что различное распределение наноструктурных элементов по поверхности определяет неравномерный цвет поверхности на микроуровне, который в совокупности влияет на результирующий цвет. Это позволяет получить новые данные о процессе формирования цвета, так как ранее подобные поверхностные структуры исследовались как набор отдельных наночастиц. В продолжении работы интерес представляет химическая, термическая и механическая устойчивости данных цветов во время эксплуатации, что является критически важными аспектами при рассмотрении перспектив внедрения данного метода окрашивания серебра в ювелирную промышленность.

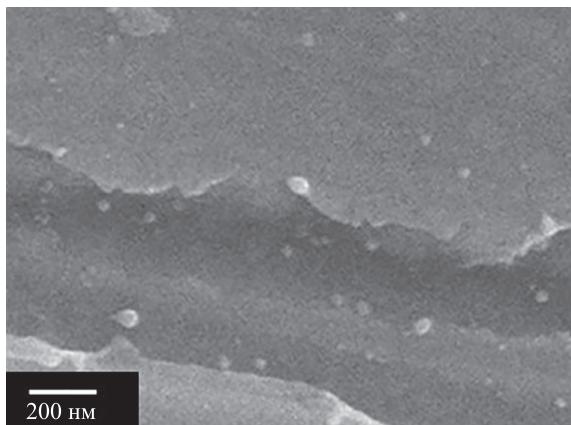


Рис. 7. СЭМ-снимки модифицируемой поверхности серебра при значении энергии в импульсе 0,04 мДж и расстоянии между импульсами 50 мкм

Fig. 7. SEM images of the modified silver surface at a pulse energy value of 0.04 mJ and a pulse distance of 50 μm

## Литература

- Kristensen A., Yang J.K.W., Bozhevolnyi S.I., Link S., Nordlander P., Halas N.J., Mortensen N.A. Plasmonic colour generation // *Nature Reviews Materials*. 2017. V. 2. N 1. P. 16088. <https://doi.org/10.1038/natrevmats.2016.88>
- Lee T., Jang J., Jeong H., Rho J. Plasmonic- and dielectric-based structural coloring: from fundamentals to practical applications // *Nano Convergence*. 2018. V. 5. N 1. P. 1. <https://doi.org/10.1186/s40580-017-0133-y>
- Duempelmann L., Casari D., Luu-Dinh A., Gallinet B., Novotny L. Color rendering plasmonic aluminum substrates with angular symmetry // *ACS Nano*. 2015. V. 9. N 12. P. 12383–12391. <https://doi.org/10.1021/acsnano.5b05710>
- Tan S.J., Zhang L., Zhu D., Goh X.M., Wang Y.M., Kumar K., Qiu C.-W., Yang J.K.W. Plasmonic color palettes for photorealistic printing with aluminum nanostructures // *Nano Letters*. 2014. V. 14. N 7. P. 4023–4029. <https://doi.org/10.1021/nl501460x>
- Wang Y., Ren F., Ding T. Generation of high quality, uniform and stable plasmonic colorants via laser direct writing // *Advanced Optical Materials*. 2020. V. 8. N 12. P. 2000164. <https://doi.org/10.1002/adom.202000164>
- Guay J.M., Lesina A.C., Côté G., Charron M., Poitras D., Ramunno L., Berini P., Weck A. Laser-induced plasmonic colours on metals // *Nature Communications*. 2017. V. 8. N 1. P. 16095. <https://doi.org/10.1038/ncomms16095>
- Cheng F., Gao J., Luk T.S., Yang X. Structural color printing based on plasmonic metasurfaces of perfect light absorption // *Scientific Reports*. 2015. V. 5. N 1. P. 11045. <https://doi.org/10.1038/srep11045>
- Andreeva Y.M., Luong V.C., Lutoshina D.S., Medvedev O.S., Mikhailovskii V.Yu., Moskvin M.K., Odintsova G.V., Romanov V.V., Shchedrina N.N., Veiko V.P. Laser coloration of metals in visual art and design // *Optical Materials Express*. 2019. V. 9. N 3. P. 1310–1319. <https://doi.org/10.1364/ome.9.001310>
- Odintsova G.V., Vlasova E.A., Andreeva Y.M., Moskvin M.K., Krivonosov A.S., Gorbunova E.V., Pankin D.V., Medvedev O.S., Sergeev M.M., Shchedrina N.N., Lutoshina D.S., Veiko V.P. High-resolution large-scale plasmonic laser color printing for jewelry applications // *Optics Express*. 2019. V. 27. N 3. P. 3672–3681. <https://doi.org/10.1364/oe.27.003672>
- Tillack M.S., Blair D.W., Harilal S.S. The effect of ionization on cluster formation in laser ablation plumes // *Nanotechnology*. 2004. V. 15. N 3. P. 390–403. <https://doi.org/10.1088/0957-4484/15/3/028>
- Boutinguiza M., Comesaña R., Lusquiños F., Riveiro A., del Val J., Pou J. Production of silver nanoparticles by laser ablation in open air // *Applied Surface Science*. 2015. V. 336. P. 108–111. <https://doi.org/10.1016/j.apsusc.2014.09.193>
- Olson J., Dominguez-Medina S., Hoggard A., Wang L.-Y., Chang W.-S., Link S. Optical characterization of single plasmonic nanoparticles // *Chemical Society Reviews*. 2015. V. 44. N 1. P. 40–57. <https://doi.org/10.1039/c4cs00131a>
- Boken J., Khurana P., Thatai S., Kumar D., Prasad S. Plasmonic nanoparticles and their analytical applications: A review // *Applied Spectroscopy Reviews*. 2017. V. 52. N 9. P. 774–820. <https://doi.org/10.1080/05704928.2017.1312427>
- Tanabe I., Tatsuma T. Plasmonic manipulation of color and morphology of single silver nanospheres // *Nano Letters*. 2012. V. 12. N 10. P. 5418–5421. <https://doi.org/10.1021/nl302919n>
- Ма С., Чжэн К., Чэн И. Свойства, применения и методы получения наносеребра // Международный студенческий научный вестник. 2018. № 6. С. 180.
- Guay J.M., Walia J., Côté G., Poitras D., Variola F., Berini P., Weck A. Effect of ps-laser repetition rate on colour rendition, nanoparticle morphology and surface chemistry on silver // *Optical Materials Express*. 2019. V. 9. N 2. P. 457–468. <https://doi.org/10.1364/ome.9.000457>

## Авторы

**Морозова Анастасия Алексеевна** — студент, инженер, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0003-2329-1288>, [aamorozova@itmo.ru](mailto:aamorozova@itmo.ru)

## References

- Kristensen A., Yang J.K.W., Bozhevolnyi S.I., Link S., Nordlander P., Halas N.J., Mortensen N.A. Plasmonic colour generation // *Nature Reviews Materials*, 2017, vol. 2, no. 1, pp. 16088. <https://doi.org/10.1038/natrevmats.2016.88>
- Lee T., Jang J., Jeong H., Rho J. Plasmonic- and dielectric-based structural coloring: from fundamentals to practical applications // *Nano Convergence*, 2018, vol. 5, no. 1, pp. 1. <https://doi.org/10.1186/s40580-017-0133-y>
- Duempelmann L., Casari D., Luu-Dinh A., Gallinet B., Novotny L. Color rendering plasmonic aluminum substrates with angular symmetry // *ACS Nano*, 2015, vol. 9, no. 12, pp. 12383–12391. <https://doi.org/10.1021/acsnano.5b05710>
- Tan S.J., Zhang L., Zhu D., Goh X.M., Wang Y.M., Kumar K., Qiu C.-W., Yang J.K.W. Plasmonic color palettes for photorealistic printing with aluminum nanostructures // *Nano Letters*, 2014, vol. 14, no. 7, pp. 4023–4029. <https://doi.org/10.1021/nl501460x>
- Wang Y., Ren F., Ding T. Generation of high quality, uniform and stable plasmonic colorants via laser direct writing // *Advanced Optical Materials*, 2020, vol. 8, no. 12, pp. 2000164. <https://doi.org/10.1002/adom.202000164>
- Guay J.M., Lesina A.C., Côté G., Charron M., Poitras D., Ramunno L., Berini P., Weck A. Laser-induced plasmonic colours on metals // *Nature Communications*, 2017, vol. 8, no. 1, pp. 16095. <https://doi.org/10.1038/ncomms16095>
- Cheng F., Gao J., Luk T.S., Yang X. Structural color printing based on plasmonic metasurfaces of perfect light absorption. *Scientific Reports*, 2015, vol. 5, no. 1, pp. 11045. <https://doi.org/10.1038/srep11045>
- Andreeva Y.M., Luong V.C., Lutoshina D.S., Medvedev O.S., Mikhailovskii V.Yu., Moskvin M.K., Odintsova G.V., Romanov V.V., Shchedrina N.N., Veiko V.P. Laser coloration of metals in visual art and design // *Optical Materials Express*, 2019, vol. 9, no. 3, pp. 1310–1319. <https://doi.org/10.1364/ome.9.001310>
- Odintsova G.V., Vlasova E.A., Andreeva Y.M., Moskvin M.K., Krivonosov A.S., Gorbunova E.V., Pankin D.V., Medvedev O.S., Sergeev M.M., Shchedrina N.N., Lutoshina D.S., Veiko V.P. High-resolution large-scale plasmonic laser color printing for jewelry applications // *Optics Express*, 2019, vol. 27, no. 3, pp. 3672–3681. <https://doi.org/10.1364/oe.27.003672>
- Tillack M.S., Blair D.W., Harilal S.S. The effect of ionization on cluster formation in laser ablation plumes. *Nanotechnology*, 2004, vol. 15, no. 3, pp. 390–403. <https://doi.org/10.1088/0957-4484/15/3/028>
- Boutinguiza M., Comesaña R., Lusquiños F., Riveiro A., del Val J., Pou J. Production of silver nanoparticles by laser ablation in open air. *Applied Surface Science*, 2015, vol. 336, pp. 108–111. <https://doi.org/10.1016/j.apsusc.2014.09.193>
- Olson J., Dominguez-Medina S., Hoggard A., Wang L.-Y., Chang W.-S., Link S. Optical characterization of single plasmonic nanoparticles. *Chemical Society Reviews*, 2015, vol. 44, no. 1, pp. 40–57. <https://doi.org/10.1039/c4cs00131a>
- Boken J., Khurana P., Thatai S., Kumar D., Prasad S. Plasmonic nanoparticles and their analytical applications: A review. *Applied Spectroscopy Reviews*, 2017, vol. 52, no. 9, pp. 774–820. <https://doi.org/10.1080/05704928.2017.1312427>
- Tanabe I., Tatsuma T. Plasmonic manipulation of color and morphology of single silver nanospheres // *Nano Letters*, 2012, vol. 12, no. 10, pp. 5418–5421. <https://doi.org/10.1021/nl302919n>
- Ma X., Zheng K., Chen Y. Properties, applications and methods of obtaining nano-silver. *Mezhdunarodnyj studencheskij nauchnyj vestnik*, 2018, no. 6, pp. 180. (in Russian)
- Guay J.M., Walia J., Côté G., Poitras D., Variola F., Berini P., Weck A. Effect of ps-laser repetition rate on colour rendition, nanoparticle morphology and surface chemistry on silver. *Optical Materials Express*, 2019, vol. 9, no. 2, pp. 457–468. <https://doi.org/10.1364/ome.9.000457>

## Authors

**Anastasia A. Morozova** — Student, Engineer, ITMO University, Saint Petersburg, 197101, Russian Federation, sc 57895979100, <https://orcid.org/0000-0003-2329-1288>, [aamorozova@itmo.ru](mailto:aamorozova@itmo.ru)

**Капустина Ульяна Александровна** — студент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0009-0001-8520-5579>, kapustinaulya@yandex.ru

**Лутошина Дарья Сергеевна** — инженер, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57205656692](https://orcid.org/0000-0003-3741-5819), [ld3282@itmo.ru](mailto:ld3282@itmo.ru)

**Романова Галина Викторовна** — кандидат технических наук, директор института лазерных технологий, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 37036063100](https://orcid.org/0000-0001-9581-4290), [https://orcid.org/0000-0001-9581-4290](mailto:gvromanova@itmo.ru), gvromanova@itmo.ru

**Ulyana A. Kapustina** — Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0009-0001-8520-5579>, kapustinaulya@yandex.ru

**Daria S. Lutoshina** — Engineer, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57205656692](https://orcid.org/0000-0003-3741-5819), [https://orcid.org/0000-0003-3741-5819](mailto:ld3282@itmo.ru), ld3282@itmo.ru

**Galina V. Romanova** — PhD, Director of the Laser Technologies Institute, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 37036063100](https://orcid.org/0000-0001-9581-4290), [https://orcid.org/0000-0001-9581-4290](mailto:gvromanova@itmo.ru), gvromanova@itmo.ru

Статья поступила в редакцию 24.05.2024  
Обобрана после рецензирования 29.07.2024  
Принята к печати 25.09.2024

Received 24.05.2024  
Approved after reviewing 29.07.2024  
Accepted 25.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

УДК 004.932.2  
doi: 10.17586/2226-1494-2024-24-5-726-737

## Алгоритм ориентирования на местности беспилотных летательных аппаратов с использованием машинного зрения

Игорь Алексеевич Зикратов<sup>1</sup>, Павел Юрьевич Беляев<sup>2</sup>✉, Евгений Андреевич Неверов<sup>3</sup>

<sup>1,2,3</sup> Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, Санкт-Петербург, 193232, Российская Федерация

<sup>1</sup> [igzikratov@yandex.ru](mailto:igzikratov@yandex.ru), <https://orcid.org/0000-0001-9054-800X>

<sup>2</sup> [monoe1337@gmail.com](mailto:monoe1337@gmail.com), <https://orcid.org/0000-0001-5387-0622>

<sup>3</sup> [datnever@ya.ru](mailto:datnever@ya.ru), <https://orcid.org/0000-0003-0733-1294>

### Аннотация

**Введение.** Одной из проблем, решаемых разработчиками беспилотных летательных аппаратов с автономным управлением, является задача определения летательным аппаратом своего точного местоположения над местностью без помощи глобальных спутниковых навигационных систем. Существующие для малогабаритных беспилотных аппаратов массогабаритные и энергетические ограничения приводят к необходимости использования в их вычислительных устройствах относительно простых алгоритмов. В работе рассмотрены методы навигации беспилотных летательных аппаратов с помощью средств компьютерного зрения, реализуемого бортовыми оптическими и вычислительными устройствами. Применяемое машинное зрение обеспечивает автономность малоразмерных летательных аппаратов при отсутствии или неустойчивом канале связи с центром управления и/или системой спутниковой навигации. **Метод.** Предлагаемый алгоритм решает задачу идентификации участка местности, наблюдаемого с беспилотного летательного аппарата, с изображением местности, заложенным в память системы управления. Местоположение аппарата определяется по минимальной (максимальной) величине невязки между наблюдаемым текущим изображением и изображением участка местности, находящимся в запоминающем устройстве. Решение задачи идентификации основано на концепции иммунокомпьютинга, использующего сингулярное разложение матрицы признаков идентифицируемых объектов. Такой подход позволяет обеспечить высокие показатели качества идентификации за счет разложения матрицы признаков на три простых преобразования для перехода в новое признаковое пространство, которое не идентифицируемо, но компоненты которого являются статистически значимыми. **Основные результаты.** Проведена оценка показателей качества разрабатываемого алгоритма в сравнении с известным методом идентификации изображений путем вычисления корреляционной функции между двумя массивами признаков. Осуществлена серия испытаний, в которых для единых исходных данных оценивались вероятность правильного определения местоположения и быстродействие алгоритмов. Показано, что при предварительной подготовке «эталонного» изображения, хранимого в запоминающем устройстве беспилотного летательного аппарата, быстродействие разработанного метода на порядок превышает производительность метода, основанного на вычислении корреляционной функции сравниваемых изображений. Средняя абсолютная ошибка правильного определения местоположения при использовании предлагаемого метода находится в диапазоне от 0,109 до 0,153. **Обсуждение.** Предложенный алгоритм может найти применение у разработчиков систем навигации для малоразмерных беспилотных летательных аппаратов благодаря его низким требованиям к ресурсам при сохранении уровня точности, достаточного в контексте решения задач ориентирования на местности. Устройства, реализующие предложенный алгоритм ориентации, обладают лучшими энергетическими и массогабаритными характеристиками.

### Ключевые слова

идентификация изображений, сингулярное разложение матриц, иммунокомпьютинг, навигация беспилотных летательных аппаратов

**Ссылка для цитирования:** Зикратов И.А., Беляев П.Ю., Неверов Е.А. Алгоритм ориентирования на местности беспилотных летательных аппаратов с использованием машинного зрения // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 726–737. doi: 10.17586/2226-1494-2024-24-5-726-737

© Зикратов И.А., Беляев П.Ю., Неверов Е.А., 2024

## Algorithm for navigation on the terrain of unmanned aerial vehicles with machine vision

Igor A. Zikratov<sup>1</sup>, Pavel U. Belyaev<sup>2</sup>✉, Evgenii A. Neverov<sup>3</sup>

<sup>1,2,3</sup> The Bonch-Bruevich Saint Petersburg State University of Telecommunications, Saint Petersburg, 193232, Russian Federation

<sup>1</sup> igzikratov@yandex.ru, <https://orcid.org/0000-0001-9054-800X>

<sup>2</sup> monoe1337@gmail.com✉, <https://orcid.org/0000-0001-5387-0622>

<sup>3</sup> datnever@ya.ru, <https://orcid.org/0000-0003-0733-1294>

### Abstract

One of the problems solved by developers of autonomously controlled unmanned aerial vehicles is the task of determining by the drone its exact position over the terrain without the help of global satellite navigation systems. The existing mass-dimensional and energy limitations for small-sized drones lead to the necessity of using relatively simple algorithms in drone computing devices. The paper considers methods of navigation of unmanned aerial vehicles using computer vision implemented by on-board optical and computing devices. Machine vision implemented by on-board computing devices provides autonomy of small-sized aircraft in the absence or unstable communication channel with the control center and/or satellite navigation system. The proposed algorithm solves the problem of identifying an area of terrain observed from a drone with a terrain image stored in the memory of the drone control system. The drone location is determined by the minimum (maximum) value of the discrepancy between the observed current image and the image of the terrain area stored in the drone memory device. The solution of the identification problem is based on the concept of immunocomputing using singular value decomposition of the feature matrix of the identified objects. This approach allows providing high quality indicators of identification due to decomposition of the feature matrix into three simple transformations for transition to a new feature space which is not identifiable, but whose components are statistically significant. The quality indicators of the developed algorithm were evaluated in comparison with the known method of image identification by calculating the correlation function between two arrays of features. A series of tests were carried out in which the probability of correct location determination and the speed of the algorithms were evaluated for the same initial data. It is shown that when pre-preparing a “reference” image stored in the drone memory device, the speed of the developed method exceeds the speed of the method based on the calculation of the correlation function of the compared images by an order of magnitude. The mean absolute error of correct positioning using the proposed method ranges from 0.109 to 0.153. The proposed algorithm can be used by developers of navigation systems for small-sized unmanned aerial vehicles due to its low resource requirements while maintaining a level of accuracy sufficient in the context of solving problems of orientation on the terrain. Devices realizing the proposed orientation algorithm have better energy and mass-size characteristics.

### Keywords

image identification, singular matrix decomposition, immunocomputing, drone navigation

**For citation:** Zikratov I.A., Belyaev P.U., Neverov E.A. Algorithm for navigation on the terrain of unmanned aerial vehicles with machine vision. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 726–737 (in Russian). doi: 10.17586/2226-1494-2024-24-5-726-737

### Введение

В настоящее время задача навигации беспилотных транспортных средств успешно решается в условиях уличной городской среды, а также внутри помещений, когда основными паттернами для извлечения информации служат дорожные знаки, светофоры и разметка. На загородных участках местности, где беспилотные летательные аппараты (БЛА) привлекаются для разведывательно-поисковых, спасательных, сельскохозяйственных и других видов работ, их навигация отличается от навигации в городских условиях из-за частичного или полного отсутствия навигационной инфраструктуры в районе применения БЛА [1]. Традиционный подход к обеспечению навигации БЛА в такой ситуации — использование системы спутниковой навигации, например ГЛОНАСС или GPS [2]. Преимуществом спутниковой навигации является достаточная точность определения местоположения на открытой местности и глобальный охват благодаря большому количеству спутников. Однако к существенному недостатку системы спутниковой навигации можно отнести большую зависимость от влияния дестабилизирующих факторов естественного и искусственного происхождения.

Альтернативный подход заключается в применении средств машинного зрения для осуществления навигации БЛА. Обзор и классификация методов построения корреляционных экстремальных систем приведен в работах [3–5], а в [6, 7] приведены примеры такого решения. В [6] предложено использовать метод RANSAC для выделения плоскостей, а также геометрических и семантических объектов в дальномерических изображениях. Метод может быть применен в условиях открытой местности, при условии достаточного количества навигационных ориентиров. В [7] представлен метод, основанный на обработке информации топологических карт. Применение данного подхода направлено на извлечение и последующую классификацию навигационных признаков, которые послужат решению задачи определения местоположения БЛА. В работах [8–10] предложено использование стереозрения для создания карты нахождения БЛА в окружающей среде с последующей сегментацией в режиме реального времени. Такой подход применим в задачах маршрутизации при наличии препятствий.

При выборе направления исследования отмечено, что для малоразмерных БЛА существуют объективные ограничения на применение ряда методов. В пер-

вую очередь к таким ограничениям следует отнести массогабаритные и, как следствие, энергетические. Ввиду небольшой емкости аккумуляторов время полета современных БЛА составляет десятки минут. На это время влияют как внешние неконтролируемые факторы (температура, влажность и т. п.), так и контролируемые факторы. К контролируемым факторам можно отнести тип батареи и энергоэффективность бортовых потребителей — двигателей, бортовых вычислительных устройств, навигационного и иного оборудования.

Следовательно, для выполнения БЛА своей основной задачи — повышения радиуса действия и полезной грузоподъемности — требуется минимизировать расход энергии бортовыми вычислительными устройствами. Помимо всего прочего это достигается использованием «энергосберегающих» алгоритмов работы бортового оборудования, в том числе систем компьютерного зрения.

Таким образом, задача, решаемая в настоящей работе, заключается в разработке алгоритма анализа изображения, имеющего меньшую, по сравнению с известными, вычислительную сложность, и, как следствие, наибольшее быстродействие. При этом точность алгоритма должны быть достаточной для практического применения.

В работе приняты следующие допущения и ограничения:

- смоделирован «полет» БЛА на одной высоте;
- размеры «скользящего» окна и «наблюдаемого» фрагмента поверхности совпадали (в пикселях);
- предполагалось, что линия визирования камеры БЛА была нормальной к поверхности;
- фотоснимки для «эталонного» и «наблюдаемого» изображений сделаны в одно время года (лето).

### Распознавание образов на основе иммунокомпьютинга

Пусть в запоминающем устройстве БЛА имеется «эталонное» цифровое представление местности, над которой выполняется полет. Тогда в бортовом вычислительном устройстве БЛА осуществляется последовательное сравнение текущего изображения участка местности, получаемое в онлайн-режиме с бортовых видеокамер, с эталонным цифровым изображением в запоминающем устройстве. При превышении величины, характеризующей «похожесть» изображений определенного порога, принимается решение об идентичности сравниваемых изображений, и фиксируются координаты текущего участка цифровой карты, соответствующие этому событию.

Для определения географического положения на основе сопоставления изображений, зафиксированных оптическими системами БЛА, с эталонным изображением со спутника используются различные методы. С помощью применения методов можно получить хорошее быстродействие, однако, существует проблема с оптимизацией информации, хранимой непосредственно в запоминающем устройстве БЛА.

Для БЛА средних и больших размеров, имеющих мощные бортовые энергоустановки, используются ме-

тоды на основе нейронных сетей [11–14], где основные паттерны местности хранятся в заранее обученной модели.

В то же время существуют методы решения задачи распознавания образов, основанные на концепции иммунокомпьютинга [15–19]. Математический аппарат иммунокомпьютинга основан на сингулярном разложении матриц (Singular Value Decomposition, SVD).

В общем случае любая матрица  $\mathbf{A}$  вещественных чисел размерностью  $m \times n$  может быть представлена с помощью сингулярного разложения вида:

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T. \quad (1)$$

В результате получаются три матрицы. Столбцы матриц  $\mathbf{U}$  ( $m \times m$ ) и  $\mathbf{V}$  ( $n \times n$ ) содержат левые и правые сингулярные векторы, вектор  $\mathbf{S}$  — сингулярные числа. Столбцы матрицы  $\mathbf{U}$  являются ортонормированными собственными векторами матрицы  $\mathbf{A}\mathbf{A}^T$ , а квадраты сингулярных чисел  $\mathbf{S} = \text{diag}(s_1, s_2, \dots, s_m)$  — ее ортонормированными собственными числами. Также столбцы матрицы  $\mathbf{V}$  являются ортонормированными собственными векторами матрицы  $\mathbf{A}^T\mathbf{A}$ , а квадраты сингулярных чисел — ее собственными числами.

SVD широко используется в машинном обучении и распознавании образов, при построении рекомендательных систем и прогнозных моделей для снижения размерности данных, аппроксимации данных методом наименьших квадратов и снижения влияния информационных шумов [20–23]<sup>1</sup>. Отличительной особенностью иммунокомпьютинга по сравнению с методом главных компонент является его вычислительная простота. Так, например, в иммунокомпьютинге нет необходимости вычислять матрицу ковариаций и производить другие вспомогательные расчеты, так как на вход алгоритма поступают «сырые» матрицы данных.

Общий подход у всех перечисленных методов к построению систем идентификации объектов заключается в построении настраиваемой модели той или иной структуры, параметры которой могут меняться. Разность величин объекта и настраиваемой модели образует невязку, которая определяет степень близости объектов друг к другу.

Согласно теории иммунокомпьютинга, левые и правые сингулярные вектора содержат атрибуты объектов обучающей выборки. В связи с этим в качестве меры невязки для определения связи между объектами  $\mathbf{A}$  и  $\mathbf{M}$  вводится понятие энергии связи, которое используется в качестве аналога расстояния между объектами. Вычислим энергию связи между двумя объектами [15]:

$$\omega = -\mathbf{U}^T \mathbf{M} \mathbf{V}. \quad (2)$$

Класс, к которому принадлежит входной образ  $\mathbf{M}$ , определяется минимальным значением энергии связи:

$$\omega_{\min} = \min(\omega).$$

<sup>1</sup> Фундаментальный пакет для научных вычислений на языке Python NumPy [Электронный ресурс]. Режим доступа: <https://numpy.org/doc/stable/reference/generated/numpy.linalg.svd.html> (дата обращения: 16.05.2024).

Для задачи определения географического положения на основе сопоставления «наблюдаемого» и «эталонного» изображений в данной работе предложен следующий алгоритм реализации концепции иммуно-компьютинга. Алгоритм содержит два этапа: предварительной обработки эталонного изображения и сканирования карты местности методом «скользящего» окна. Этапы представляют собой последовательность и связаны друг с другом.

### Этап предварительной обработки эталонного изображения

Рассмотрим спутниковые фотографии одного и того же участка местности, сделанные в разное время различными космическими аппаратами (рис. 1).

В качестве карты местности выбрана область на северо-западе Санкт-Петербурга. Импорт изображений осуществлен с сервисов GoogleMaps и Яндекс.Карты. Фотографии отличаются друг от друга масштабом, цветом и уровнем детализации паттернов. Значительная часть местности покрыта лесным массивом, не имеющим каких-либо идентификационных элементов. При моделировании работы алгоритма одно изображение использовалось в качестве «эталонного», которое содержится в запоминающем устройстве БЛА. Другое — в качестве «наблюдаемого» изображения из камеры БЛА.

С целью снижения размерности вычислений на этом этапе осуществляется преобразование пикселов изображения из цветного формата представления к оттенкам серого. Для этого использована известная формула [24]:

$$Y' = 0,2989R + 0,5870G + 0,1140B. \quad (3)$$

Для выравнивания значений интенсивности пикселов выполнена стандартная операция нормализации массивов изображений:

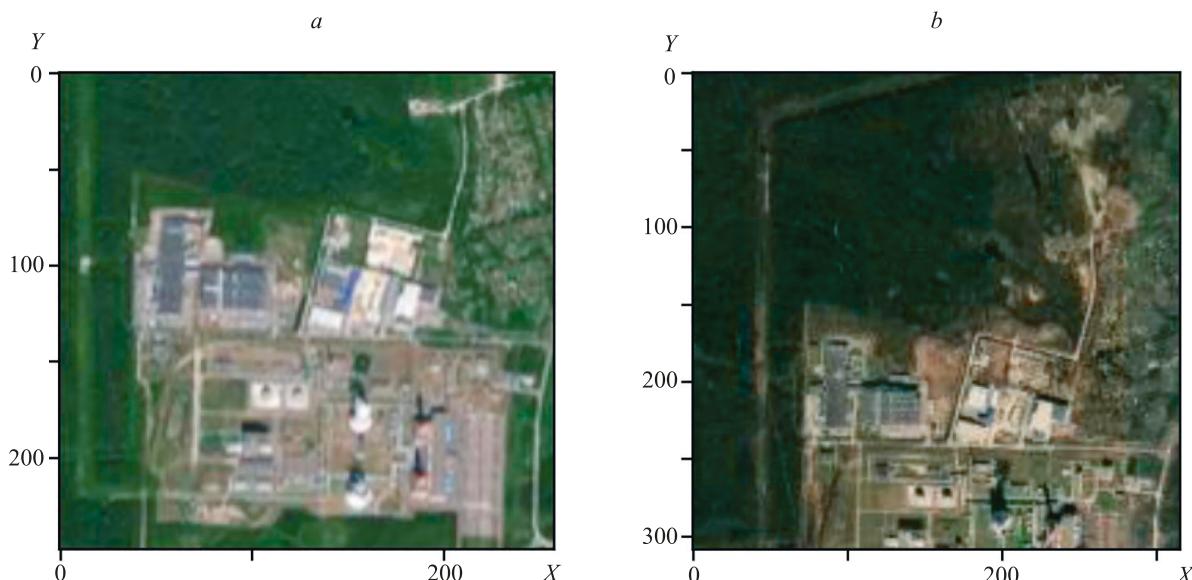


Рис. 1. «Эталонный» (a) и «наблюдаемый» (b) участки местности.

Размеры рисунков в пикселях

Fig. 1. “Reference” (a) and “observed” (b) terrain plots (image sizes in pixels)

$$X_{norm} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}. \quad (4)$$

Результат преобразования изображений по формулам (3) и (4) представлен на рис. 2.

После предобработки в качестве «эталонной» карты местности в запоминающем устройстве БЛА выбрано изображение, импортированное и преобразованное в монохромное из сервиса GoogleMaps. В качестве имитации «наблюдаемого» изображения с борта «летящего» БЛА использовано окно, представляющее собой фрагмент изображения размера  $m \times n$ , импортированного из сервиса Яндекс.Карты.

### Этап сканирования карты местности методом «скользящего» окна

На этапе сканирования карты местности выполнена следующая итерационная процедура [15].

Шаг 1. Выбор текущего начального участка на «эталонной» карте местности, размеры которого совпадают с размером изображения, «наблюдаемого» бортовыми средствами БЛА. Значения пикселов этого участка после их преобразования по формулам (3) и (4) записаны в матрицу  $\mathbf{A}$ .

Шаг 2. По формуле (1) выполнено сингулярное разложение матрицы  $\mathbf{A}$ , и запоминание тех столбцов матрицы  $\mathbf{U}$  и  $\mathbf{V}^T$ , которые соответствуют максимальному сингулярному числу вектора  $\mathbf{S}$ . Операция сингулярного разложения осуществлена с использованием соответствующей функции библиотеки NumPy языка Python<sup>1</sup>.

Так, например, матрицы  $\mathbf{U}$  и  $\mathbf{V}^T$ , полученные в результате SVD-матрицы значений пикселов, соот-

<sup>1</sup> numpy.linalg.svd [Электронный ресурс]. Режим доступа: <https://numpy.org/doc/stable/reference/generated/numpy.linalg.svd.html> (дата обращения: 10.07.2024).

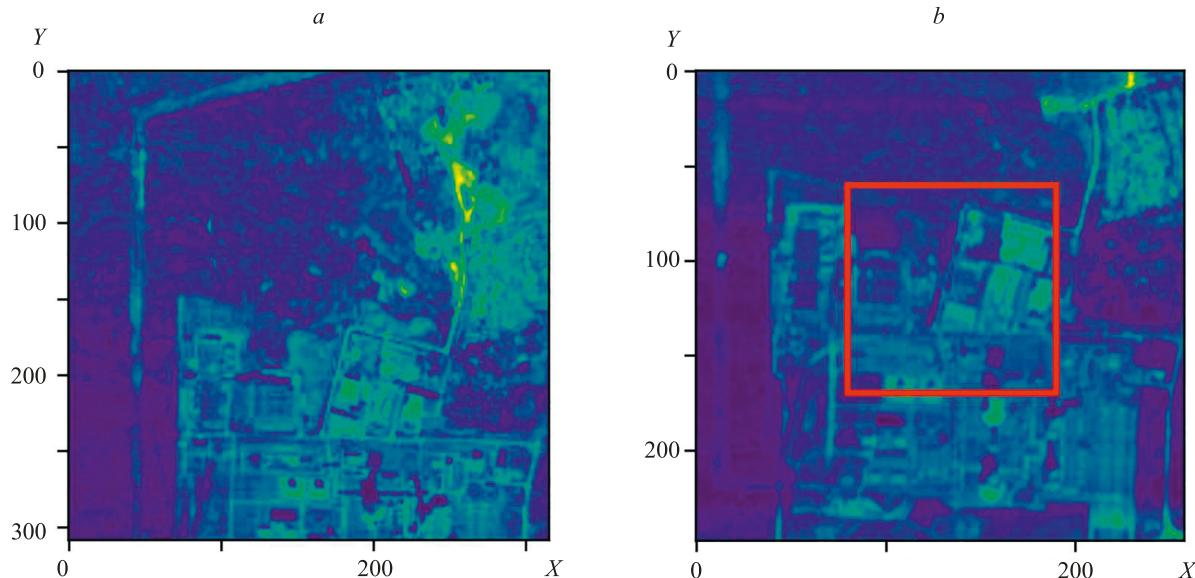


Рис. 2. «Эталонный» (а) и «наблюдаемый» (б) участки местности после нормализации изображений.

Красным прямоугольником отмечен фрагмент местности, «наблюдаемый» беспилотным летательным аппаратом в текущий момент времени. Размеры рисунков в пикселях

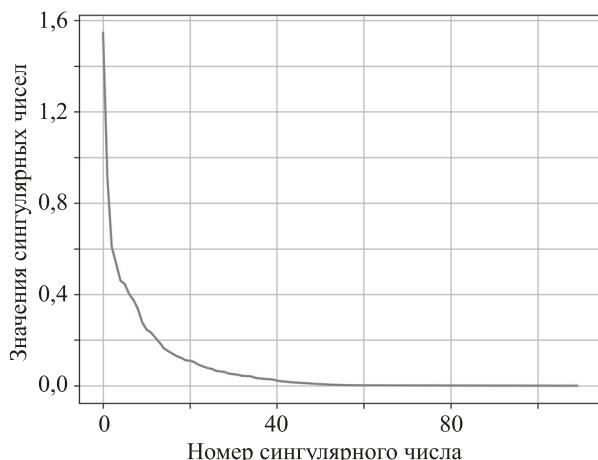
Fig. 2. “Reference” (a) and “observed” (b) terrain areas after image normalization (image sizes in pixels)

всегда соответствующей выделенному фрагменту изображения  $90 \times 90$  пикселов на рис. 2, имеют вид:

$$\mathbf{U} = \begin{pmatrix} -0,08796 & \dots & 0,05652 \\ -0,08988 & \dots & 0,03449 \\ \vdots & \ddots & \vdots \\ -0,12707 & \dots & 0,29215 \\ -0,12587 & \dots & -0,12200 \end{pmatrix},$$

$$\mathbf{V}^T = \begin{pmatrix} -0,22499 & \dots & 0,15026 \\ 0,20534 & \dots & 0,09593 \\ \vdots & \ddots & \vdots \\ 0,00293 & \dots & -0,05942 \\ 0,14370 & \dots & -0,07863 \end{pmatrix}.$$

Значения вектора  $\mathbf{S}$  представлены на рис. 3.

Рис. 3. Сингулярные числа вектора  $\mathbf{S}$ Fig. 3. Singular numbers of vector  $\mathbf{S}$ 

Как видно из рис. 3, максимальное значение имеет первое сингулярное число вектора  $\mathbf{S}$ , поэтому, в соответствии с формулой (2), необходимо использовать вектор-строку  $-\mathbf{U}_1^T$  и вектор-столбец  $\mathbf{V}_1$ . Для рассматриваемого примера они имеют вид:

$$-\mathbf{U}_1^T = [0,08796, 0,08998, \dots, 0,12707, 0,12587];$$

$$\mathbf{V}_1 = \begin{bmatrix} -0,22449 \\ -0,23216 \\ \dots \\ 0,13970 \\ 0,15026 \end{bmatrix}.$$

Шаг 3. Вычисление энергии связи  $\omega_i$  по формуле (2). Здесь  $i = 1, K$ , где  $K$  — количество «скользящих окон», т. е. фрагментов «эталонной» карты местности, сравниваемых с «наблюдаемым» изображением. В качестве матрицы  $\mathbf{M}$  в формуле (1) использована матрица, содержащая значения пикселов «наблюдаемого» изображения, после их преобразования по формулам (3) и (4).

Шаг 4. Запоминание значения энергии связи  $\omega_i$   $i$ -го участка местности и соответствующих этому участку координат на «эталонной» карте местности.

Шаг 5. Повторение шагов 2–3 до тех пор, пока «скользящее» окно не достигнет конца «эталонной» карты.

Шаг 6. Поиск минимального значения энергии связи  $\omega_{\min} = \omega_i$ , нахождение которого свидетельствует, что  $i$ -й участок на «эталонной» карте имеет максимальное сходство с «наблюдаемым» изображением, описываемым матрицей  $\mathbf{M}$ .

## Результаты экспериментов

Работоспособность предлагаемого алгоритма проверена путем имитационного моделирования. В качестве

исходных данных использовались «эталонное» и «наблюдаемое» изображения на рис. 2.

Выполнен сравнительный анализ полученных результатов с известным методом определения похожести изображения, основанном на вычислении коэффициента корреляции Пирсона между двумя массивами  $\mathbf{X}$  и  $\mathbf{Y}$ :

$$r(\mathbf{X}, \mathbf{Y}) = \frac{\sum(x - \bar{x})(y - \bar{y})}{\sqrt{\sum(x - \bar{x})^2 \sum(y - \bar{y})^2}}$$

При сравнении методов проведена оценка точности и быстродействия предлагаемого алгоритма на основе иммунокомпьютинга в сравнении с алгоритмом на основе корреляции Пирсона.

### Оценка точности алгоритмов

Рассмотрим две противоположные ситуации.

**Ситуация 1.** В качестве «наблюдаемого» изображения выбран участок местности без видимых паттернов (рис. 4).

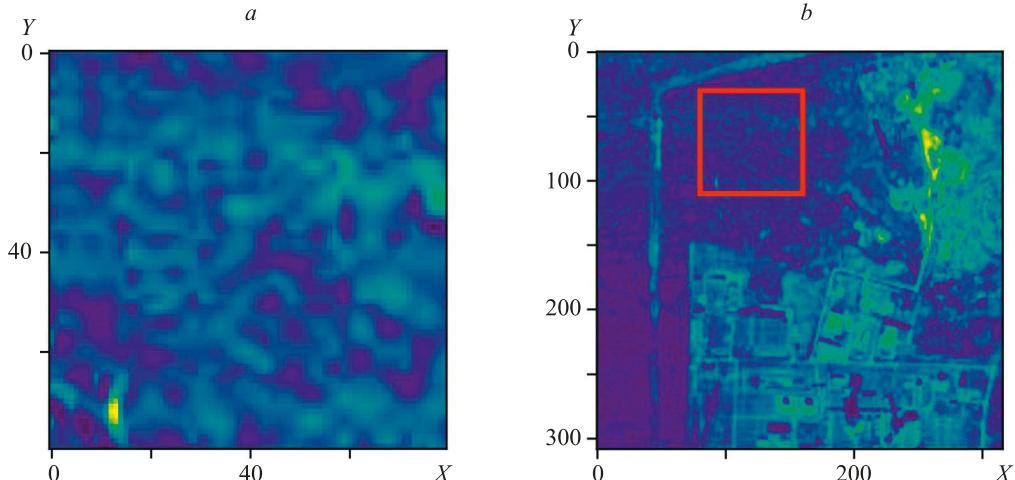


Рис. 4. Ситуация 1. «Наблюдаемый» беспилотным летательным аппаратом участок местности (a) и его текущее местоположение на карте (b).

Красным прямоугольником отмечен фрагмент местности, «наблюдаемый» аппаратом в текущий момент времени. Размеры рисунков в пикселях

Fig. 4. Situation 1. The area of “observed” terrain by UAV (a) and its current location on the map (b) (image sizes in pixels)

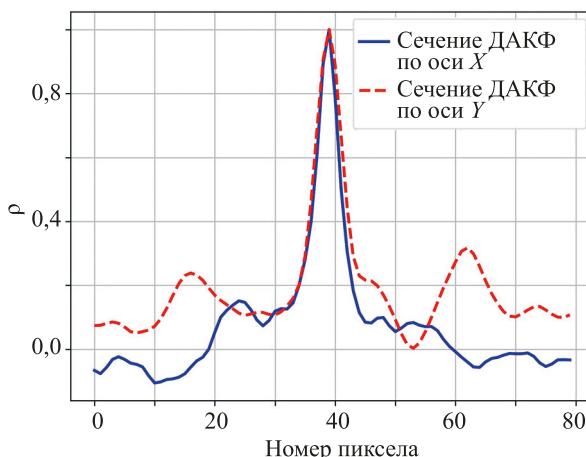


Рис. 5. Двумерная автокорреляционная функция (ДАКФ) изображения участка местности без видимых паттернов

Fig. 5. STDAF image of an area of terrain with no visible patterns

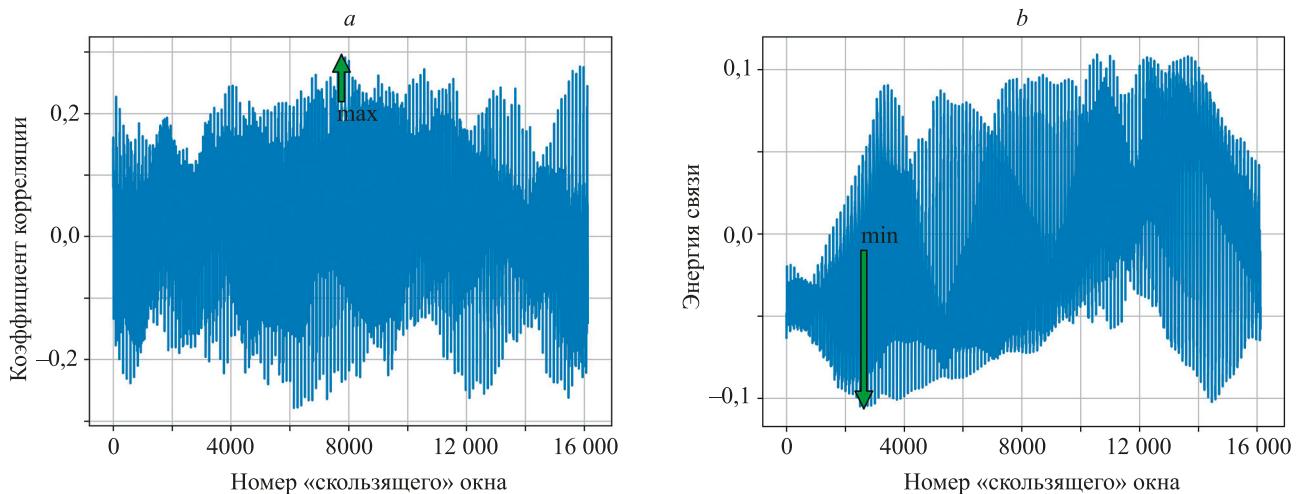


Рис. 6. Ситуация 1. Результаты вычисления коэффициента корреляции  $r$  (а) и энергии связи  $\omega$  (б) при перемещении «скользящего» окна

Fig. 6. Situation 1. Results of calculation of (a) correlation coefficient  $r$  and (b) linking energy when moving the «sliding» window

окон (рис. 7) не соответствуют местоположению «наблюдаемого» участка (рис. 4).

Как видно из рис. 7, в отсутствие паттернов на местности оба алгоритма не способны определить местоположение «наблюдаемого» участка.

**Ситуация 2.** На «наблюдаемом» участке присутствуют паттерны.

На рис. 8 имеются несколько строений и дорог, имеющих характерную конфигурацию. Радиус корреляции ситуации 2 по уровню 0,5 составил десятки пикселов (рис. 9).

В данной ситуации оба алгоритма показали одинаковый результат (рис. 10, 11).

Очевидно, что в условиях, когда явно видно конфигурацию и местоположение паттернов, предлага-

емый алгоритм не уступает по точности корреляции Пирсона.

Оценка точности алгоритмов осуществлена путем проведения вычислительного эксперимента. Для этого на «наблюдаемом» участке местности произвольно выбирались координаты текущего местоположения БЛА, и в соответствии с описанной итерационной процедурой осуществлялся расчет невязки фрагментов изображения на «наблюдаемой» и «эталонной» картах при различных размерах «скользящего» окна. В качестве «невязки» использовался широко используемый в регрессионном анализе параметр MAE (Mean Absolute Error, средняя абсолютная ошибка) — оценка того, насколько близки предсказания к фактическим значениям. Эта метрика менее чувствительна к выбросам и может

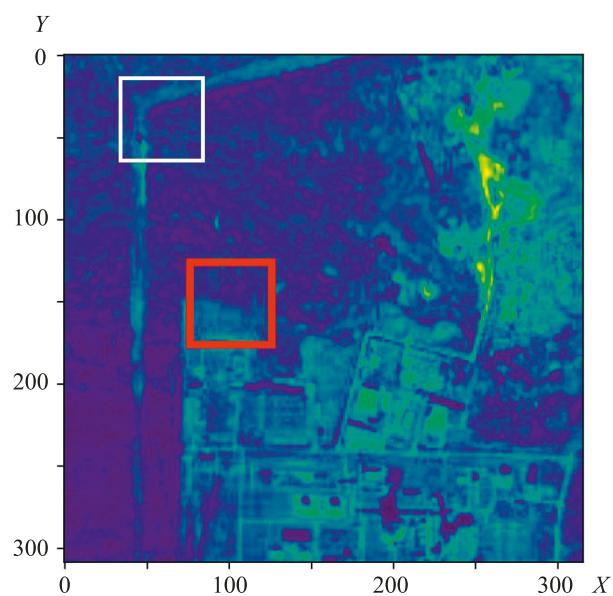


Рис. 7. «Эталонная» карта. Результат работы алгоритмов для ситуации 1.

Красным цветом обозначен участок, определенный в качестве местоположения беспилотным летательным аппаратом с использованием корреляции Пирсона, белым — с использованием энергии связи. Размеры рисунков в пикселях

Fig. 7. «Reference» map. The result of the algorithms for situation 1 (image sizes in pixels)

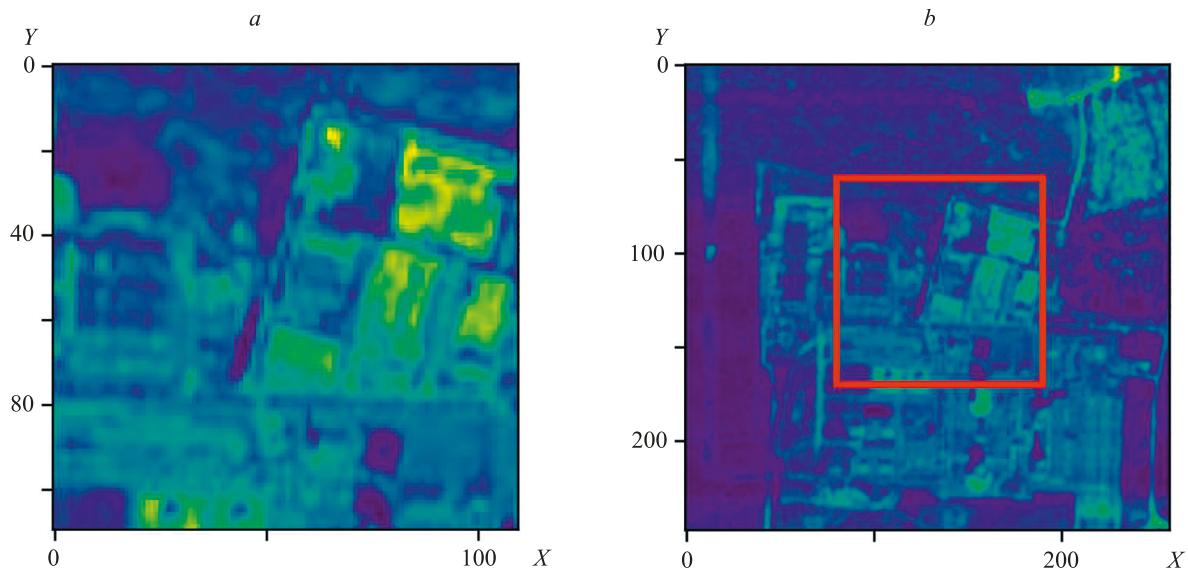


Рис. 8. Ситуация 2. «Наблюдаемый» беспилотным летательным аппаратом участок местности (а) и его текущее местоположение на карте (б).

Красным прямоугольником отмечен фрагмент местности, «наблюдаемый» беспилотным летательным аппаратом в текущий момент времени. Размеры рисунков в пикселях

Fig. 8. Situation 2. The area of the “observed” terrain by UAV and its current location on the map (image sizes in pixels)

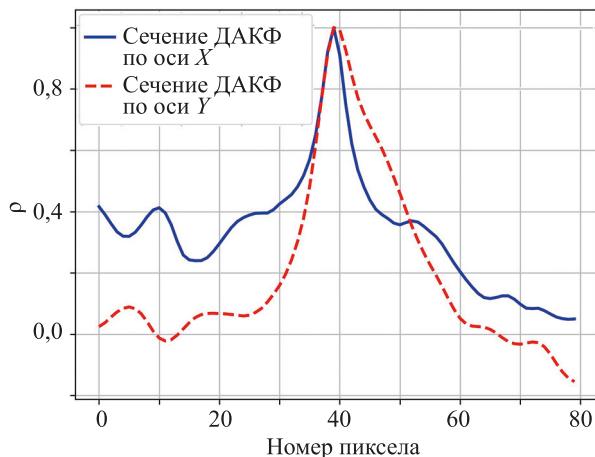


Рис. 9. Двумерная автокорреляционная функция (ДАКФ) изображения участка местности с «наблюдаемыми» паттернами  
Fig. 9. STDAF of the image of a terrain section with “observed” patterns

дать общее представление о качестве модели. В данном случае показатель MAE характеризует насколько точно на эталонном изображении найдено «наблюдаемое».

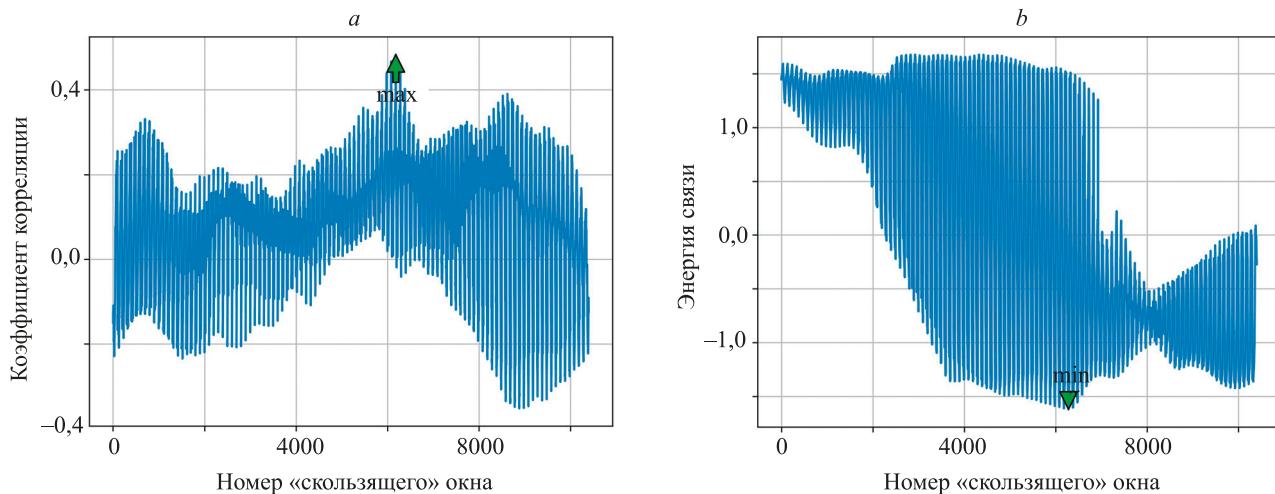
Оценка осуществлялась по результатам 1000 испытаний, для ситуаций 1 и 2 с радиусом корреляции от единиц до десятков пикселов. Средние значения представлены в табл. 1.

Из расчетов следует, что с увеличением размеров наблюдаемой БЛА области результаты иммунокомпьютинга и корреляции Пирсона сближаются.

Следует отметить, что существуют более совершенные алгоритмы оценки точности совмещения изображений, например в работе [25], которые требуют адаптации к рассматриваемой задаче.

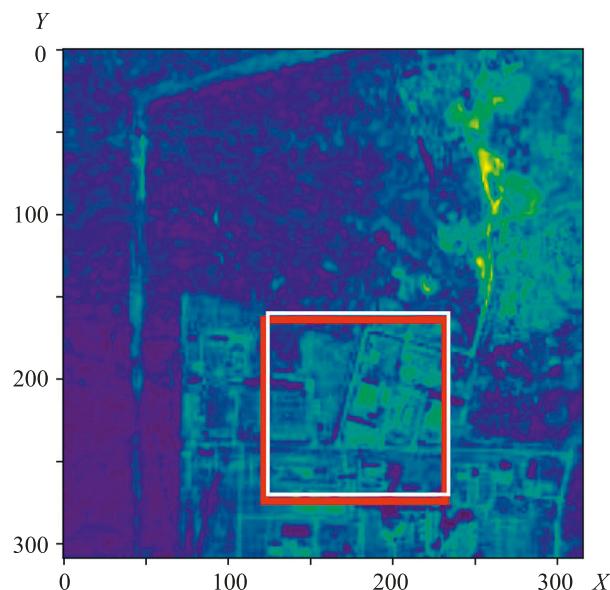
Таблица 1. Средняя абсолютная ошибка определения местоположения БЛА при различных размерах «скользящего» окна  
Table 1. Mean absolute error of UAV location at different “sliding” window sizes

Алгоритм	Размер окна, пикселов		
	70 × 70	80 × 80	90 × 90
Корреляция Пирсона	0,153	0,130	0,128
Иммунокомпьютинг	0,109	0,121	0,138



*Рис. 10.* Ситуация 2. Результаты вычисления: коэффициента корреляции  $r$  (*a*) и энергии связи  $\omega$  (*b*) при перемещении «скользящего» окна

*Fig. 10.* Situation 2. Results of calculation of (*a*) correlation coefficient  $r$  and (*b*) linking energy  $\omega$  when moving the “sliding” window



*Рис. 11.* «Эталонная» карта. Результат работы алгоритмов для ситуации 2.

Красным цветом обозначен участок, определенный в качестве местоположения беспилотным летательным аппаратом с использованием корреляции Пирсона, белым — с использованием энергии связи. Размеры рисунков в пикселях.

*Fig. 11.* “Reference” map. The result of the algorithms for situation 2 (image sizes in pixels)

### Оценка быстродействия алгоритмов

Оценка быстродействия алгоритмов выполнена для трех размеров окон:  $40 \times 40$ ,  $70 \times 70$  и  $100 \times 100$  пикселей. Использован процессор Intel(R) Core(TM) i3-6300 CPU @ 3.80 GHz. Расчет осуществлен при условии, что в оперативной памяти уже загружено «эталонное» изображение местности, а также необходимые для расчета переменные и константы. Фиксировалось время начала вычисления функции невязки при начальном положении «скользящего» окна, и время достижения «скользящего» окна конечного положения на изображении. Результаты приведены в табл. 2.

Как следует из результатов оценки, быстродействие предлагаемого алгоритма меньше, чем при вычислении корреляционной функции. Это объясняется большим количеством операций, а именно — необходимостью сингулярного разложения каждой матрицы пикселов «скользящего» окна.

Однако эти операции могут быть выполнены заблаговременно, на этапе предполетной подготовки БЛА (ситуация 3). Тогда в запоминающем устройстве БЛА будет загружено не цифровое изображение местности после операций монокроматизации и нормировки (рис. 2), а значения левых и правых сингулярных векторов  $-U_1^T$  и  $V_1$ , вычисленных для каждого дискретного

*Таблица 2.* Оценка быстродействия алгоритмов при загруженном «эталонном» изображении, с  
*Table 2.* Evaluation of algorithms performance with loaded “reference” image

Алгоритм	Размер окна, пикселов		
	40 × 40	70 × 70	100 × 100
Корреляция Пирсона	20,9	31,6	46,9
Иммунокомпьютинг	23,8	36,0	52,7

*Таблица 3.* Оценка быстродействия алгоритмов при загруженных сингулярных векторах, с  
*Table 3.* Evaluation of algorithms performance under loaded singular vectors, in s

Алгоритм	Размер окна, пикселов		
	40 × 40	70 × 70	100 × 100
Корреляция Пирсона	20,9	31,6	46,9
Иммунокомпьютинг	0,91	2,12	2,70

положения «скользящего» окна. Результаты расчетов для ситуации 3 представлены в табл. 3.

Из результатов расчетов следует, что предобработка эталонного изображения позволила на порядок увеличить быстродействие алгоритма иммунокомпьютинга. Так при размерах окна  $100 \times 100$  пикселов, быстродействие алгоритма составляет единицы секунд. На практике это позволяет в процессе полета более часто осуществлять навигацию БЛА без существенных вычислительных затрат.

### Заключение

Таким образом, результаты исследования показывают, что использование предлагаемого алгоритма в

навигационных системах позволяет в ряде случаев обеспечить навигацию беспилотным летательным аппаратом на местности на основе методов компьютерного зрения. Для этого топопривязку необходимо осуществлять в тех районах, которые имеют визуально различные паттерны — дороги, реки, строения, населенные пункты и т. п. При этом, по сравнению с известными методами, предложенный алгоритм обладает высоким быстродействием при сопоставимой точности, и, как следствие, обеспечивается энергоэффективность бортовых устройств беспилотным летательным аппаратом.

Дальнейшие исследования будут направлены на снятие описанных в работе ограничений.

### Литература

- Кабалдин Ю.Г., Киселёв А.В., Шатагин Д.А. Концепция разработки маршрута движения беспилотного транспортного средства в условиях Арктики // Евразийский Союз Ученых. 2016. № 31-1. С. 63–66.
- Wells D., Beck N. Guide to GPS positioning. Canadian GPS Assoc, 1987. 600 p.
- Бочкирев А.М. Корреляционно-экстремальные системы навигации // Зарубежная радиоэлектроника. 1981. № 9. С. 28–53.
- Белоглазов И.Н., Тарасенко В.П. Корреляционно-экстремальные системы. М.: Советское радио, 1974. 392 с.
- Тарасенко В.П., Тимофеев А.В. Доверительное оценивание точности совмещения в корреляционно-экстремальных системах // Автоматрия. 1990. № 4. Р. 106–111.
- Казьмин В.Н., Носков В.П. Выделение геометрических и семантических объектов в дальномерических изображениях для навигации роботов и реконструкции внешней среды // Известия Южного федерального университета. Технические науки. 2015. № 10(171). С. 71–83.
- Marinho L.B., Rebouças Filho P.P., Almeida J.S., Souza J.W.M., Souza Jr A.H., de Albuquerque V.H.C. A novel mobile robot localization approach based on classification with rejection option using computer vision // Computers & Electrical Engineering. 2018. V. 68. P. 26–43. <https://doi.org/10.1016/j.compeleceng.2018.03.047>
- Murray D., Little J.J. Using real-time stereo vision for mobile robot navigation // Autonomous Robots. 2000. V. 8. N 2. P. 161–171. <https://doi.org/10.1023/A:1008987612352>
- Lulio L.C., Tronco M.L., Porto A.J.V. JSEG-based image segmentation in computer vision for agricultural mobile robot navigation // Proc. of the IEEE International Symposium on Computational Intelligence in Robotics and Automation — (CIRA), 2009, pp. 240–245. <https://doi.org/10.1109/cira.2009.5423201>

### References

- Kabaldin Iu.G., Kiselev A.V., Shatagin D.A. The concept of developing a route for an unmanned vehicle in the Arctic conditions. *Eurasian Union of Scientists*, 2016, no. 31-1, pp. 63–66. (in Russian)
- Wells D., Beck N. *Guide to GPS positioning*. Canadian GPS Assoc, 1987, 600 p.
- Bochkarev A.M. Correlation extreme navigation systems. *Zarubezhnaja radioelektronika*, 1981, no. 9, pp. 28–53. (in Russian)
- Beloglazov I.N., Tarasenko V.P. *Correlation Extreme Systems*. Moscow, Sovetskoe Radio Publ., 1974, 392 p. (in Russian)
- Tarasenko V.P., Timofeev A.V. Confidence estimation of registration precision in correlation-extreme systems. *Avtometriya*, 1990, no. 4, pp. 106–111. (in Russian)
- Kazmin V.N., Noskov V.P. Detecting geometric and semantic objects in range image for robot navigation and environment reconstruction. *Izvestiya SFedU. Engineering Sciences*, 2015, no. 10(171), pp. 71–83. (in Russian)
- Marinho L.B., Rebouças Filho P.P., Almeida J.S., Souza J.W.M., Souza Jr A.H., de Albuquerque V.H.C. A novel mobile robot localization approach based on classification with rejection option using computer vision. *Computers & Electrical Engineering*, 2018, vol. 68, pp. 26–43. <https://doi.org/10.1016/j.compeleceng.2018.03.047>
- Murray D., Little J.J. Using real-time stereo vision for mobile robot navigation. *Autonomous Robots*, 2000, vol. 8, no. 2, pp. 161–171. <https://doi.org/10.1023/A:1008987612352>
- Lulio L.C., Tronco M.L., Porto A.J.V. JSEG-based image segmentation in computer vision for agricultural mobile robot navigation. *Proc. of the IEEE International Symposium on Computational Intelligence in Robotics and Automation — (CIRA)*, 2009, pp. 240–245. <https://doi.org/10.1109/cira.2009.5423201>

- Computational Intelligence in Robotics and Automation — (CIRA). 2009. P. 240–245. <https://doi.org/10.1109/cira.2009.5423201>
10. Hussein A., Marin-Plaza P., Martin D., de la Escalera A., Armingol J.M. Autonomous off-road navigation using stereo-vision and laser-rangefinder fusion for outdoor obstacles detection // Proc. of the IEEE Intelligent Vehicles Symposium (IV). 2016. P. 104–109. <https://doi.org/10.1109/ivs.2016.7535372>
  11. Sozzi M., Kayad A., Marinello F., Taylor J., Tisseyre B. Comparing vineyard imagery acquired from Sentinel-2 and Unmanned Aerial Vehicle (UAV) platform // OENO One. 2020. V. 54. N 2. P. 189–197. <https://doi.org/10.20870/oenone.2020.54.1.2557>
  12. Pastonchi L., Di Gennaro S.F., Toscano P., Matese A. Comparison between satellite and ground data with UAV-based information to analyse vineyard spatio-temporal variability: This article is published in cooperation with the XIII<sup>th</sup> International Terroir Congress November 17–18, 2020, Adelaide, Australia. Guest editors: Cassandra Collins and Roberta De Bei // OENO One. 2020. V. 54. N 4. P. 919–934. <https://doi.org/10.20870/oenone.2020.54.4.4028>
  13. Lu Z., Liu F., Lin X. Vision-based localization methods under GPS-denied conditions // arXiv. 2022. arXiv:2211.11988. <https://doi.org/10.48550/arXiv.2211.11988>
  14. Lu K., Xu R., Li J., Lv Y., Lin H., Liu Y. A vision-based detection and spatial localization scheme for forest fire inspection from UAV // Forests. 2022. V. 13. N 3. P. 383. <https://doi.org/10.3390/f13030383>
  15. Tarakanov A., Skormin V., Sokolova S. Immunocomputing: Principles and Applications. New York, NY: Springer, 2003. 193 p.
  16. Tarakanov A., Nicosia G. Foundations of immunocomputing // Proc. of the IEEE Symposium on Foundations of Computational Intelligence. 2007. P. 503–508. <https://doi.org/10.1109/foci.2007.371519>
  17. Tarakanov A.O. Mathematical models of intrusion detection by an intelligent immunochip // Communications in Computer and Information Science. 2013. V. 1. P. 308–319. [https://doi.org/10.1007/978-3-540-73986-9\\_26](https://doi.org/10.1007/978-3-540-73986-9_26)
  18. Соломатин А.Ю., Зикратов И.А. Метод идентификации человека по изображению лица в системах видеонаблюдения на основе научно-методического аппарата иммунокомпьютинга // Информация и космос. 2015. № 2. С. 47–51.
  19. Соломатин А.Ю., Люберт А.С., Зикратов И.А. Идентификация движущегося человека в системах видеонаблюдения // Научно-технический вестник информационных технологий, механики и оптики. 2014. № 4(92). С. 124–131.
  20. Губин А.Н., Литвинов В.Л., Филиппов Ф.В. Использование метода главных компонент для распознавания графических объектов // Труды учебных заведений связи. 2016. Т. 2. № 3. С. 27–31.
  21. Litvinov V.L., Kozlova L.P., Filippov F.V. The use of a matrix decompositions for dimension reduction of training sample // Proc. of the IEEE II International Conference on Control in Technical Systems (CTS). 2017. P. 282–284. <https://doi.org/10.1109/CTSYS.2017.8109546>
  22. Alieva O., Gangan E., Ilyushin E., Kachalin A. Automatic evaluation of recommendation models // Современные информационные технологии и ИТ-образование. 2020. Т. 16. № 2. С. 398–406. <https://doi.org/10.25559/SITITO.16.202002.398-406>
  23. Минин А.С. Применение сингулярного разложения для понижения размерности в анализе данных // Тенденции развития науки и образования. 2023. № 99-7. С. 55–58. <https://doi.org/10.18411/trnio-07-2023-377>
  24. Studio encoding parameters of digital television for standard 4: 3 and wide-screen 16: 9 aspect ratios: Recommendation ITU-R BT.601-7 (03/2011).
  25. Тимофеев А.В. Инвариантный к линейным конформным преобразованиям алгоритм обнаружения размытого изображения цлевого объекта малого размера // Научно-технический вестник информационных технологий, механики и оптики. 2021. Т. 21. № 2. С. 206–224. <https://doi.org/10.17586/2226-1494-2021-21-2-206-224>
  10. Hussein A., Marin-Plaza P., Martin D., de la Escalera A., Armingol J.M. Autonomous off-road navigation using stereo-vision and laser-rangefinder fusion for outdoor obstacles detection. *Proc. of the IEEE Intelligent Vehicles Symposium (IV)*, 2016, pp. 104–109. <https://doi.org/10.1109/ivs.2016.7535372>
  11. Sozzi M., Kayad A., Marinello F., Taylor J., Tisseyre B. Comparing vineyard imagery acquired from Sentinel-2 and Unmanned Aerial Vehicle (UAV) platform. *OENO One*, 2020, vol. 54, no. 2, pp. 189–197. <https://doi.org/10.20870/oenone.2020.54.1.2557>
  12. Pastonchi L., Di Gennaro S.F., Toscano P., Matese A. Comparison between satellite and ground data with UAV-based information to analyse vineyard spatio-temporal variability: This article is published in cooperation with the XIII<sup>th</sup> International Terroir Congress November 17–18, 2020, Adelaide, Australia. Guest editors: Cassandra Collins and Roberta De Bei. *OENO One*, 2020, vol. 54, no. 4, pp. 919–934. <https://doi.org/10.20870/oenone.2020.54.4.4028>
  13. Lu Z., Liu F., Lin X. Vision-based localization methods under GPS-denied conditions. *arXiv*, 2022, arXiv:2211.11988. <https://doi.org/10.48550/arXiv.2211.11988>
  14. Lu K., Xu R., Li J., Lv Y., Lin H., Liu Y. A vision-based detection and spatial localization scheme for forest fire inspection from UAV. *Forests*, 2022, vol. 13, no. 3, pp. 383. <https://doi.org/10.3390/f13030383>
  15. Tarakanov A., Skormin V., Sokolova S. *Immunocomputing: Principles and Applications*. New York, NY: Springer, 2003, 193 p.
  16. Tarakanov A., Nicosia G. Foundations of immunocomputing. *Proc. of the IEEE Symposium on Foundations of Computational Intelligence*, 2007, pp. 503–508. <https://doi.org/10.1109/foci.2007.371519>
  17. Tarakanov A.O. Mathematical models of intrusion detection by an intelligent immunochip. *Communications in Computer and Information Science*, 2013, vol. 1, pp. 308–319. [https://doi.org/10.1007/978-3-540-73986-9\\_26](https://doi.org/10.1007/978-3-540-73986-9_26)
  18. Solomatin A.Y., Zikratov I.A. Method of person identification by the facial image in video surveillance system using scientific methods of immunocomputing. *Information and Space*, 2015, no. 2, pp. 47–51. (in Russian)
  19. Solomatin A.Y., Lyubert A.S., Zikratov I.A. Moving person identification in video surveillance systems. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2014, no. 4(92), pp. 124–131. (in Russian)
  20. Gubin A., Litvinov V., Filippov F. Use of a principal component analysis for the recognition of the graphic objects. *Proceedings of Telecommunication Universities*, 2016, vol. 2, no. 3, pp. 27–31. (in Russian)
  21. Litvinov V.L., Kozlova L.P., Filippov F.V. The use of a matrix decompositions for dimension reduction of training sample. *Proc. of the IEEE II International Conference on Control in Technical Systems (CTS)*, 2017, pp. 282–284. <https://doi.org/10.1109/CTSYS.2017.8109546>
  22. Alieva O., Gangan E., Ilyushin E., Kachalin A. Automatic evaluation of recommendation models. *Modern information technologies and IT-education*, 2020, vol. 16, no. 2, pp. 398–406. (in Russian). <https://doi.org/10.25559/SITITO.16.202002.398-406>
  23. Minin A.S. Application of singular value decomposition to reduce dimensionality in data analysis. *Tendencii razvitiya nauki i obrazovanija*, 2023, no. 99-7, pp. 55–58. (in Russian). <https://doi.org/10.18411/trnio-07-2023-377>
  24. Studio encoding parameters of digital television for standard 4: 3 and wide-screen 16: 9 aspect ratios. Recommendation ITU-R BT.601-7 (03/2011).
  25. Timofeev A.V. Detection of a small target object in blurry images affected by affine distortions. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2021, vol. 21, no. 2, pp. 206–224. (in Russian). <https://doi.org/10.17586/2226-1494-2021-21-2-206-224>

## Авторы

**Зикратов Игорь Алексеевич** — доктор технических наук, профессор, декан, Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, Санкт-Петербург, 193232, Российская Федерация, 56321572700, <https://orcid.org/0000-0001-9054-800X>, igzikratov@yandex.ru

## Authors

**Igor A. Zikratov** — D.Sc., Professor, Dean, The Bonch-Bruevich Saint Petersburg State University of Telecommunications, Saint Petersburg, 193232, Russian Federation, 56321572700, <https://orcid.org/0000-0001-9054-800X>, igzikratov@yandex.ru

**Беляев Павел Юрьевич** — аспирант, Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, Санкт-Петербург, 193232, Российская Федерация, [sc 57224353414](#), <https://orcid.org/0000-0001-5387-0622>, monoe1337@gmail.com

**Неверов Евгений Андреевич** — аспирант, Санкт-Петербургский государственный университет телекоммуникаций им. проф. М.А. Бонч-Бруевича, Санкт-Петербург, 193232, Российская Федерация, [sc 57224353038](#), <https://orcid.org/0000-0003-0733-1294>, datnever@ya.ru

**Pavel U. Belyaev** — PhD Student, The Bonch-Bruevich Saint Petersburg State University of Telecommunications, Saint Petersburg, 193232, Russian Federation, [sc 57224353414](#), <https://orcid.org/0000-0001-5387-0622>, monoe1337@gmail.com

**Evgenii A. Neverov** — PhD Student, The Bonch-Bruevich Saint Petersburg State University of Telecommunications, Saint Petersburg, 193232, Russian Federation, [sc 57224353038](#), <https://orcid.org/0000-0003-0733-1294>, datnever@ya.ru

*Статья поступила в редакцию 29.05.2024  
Одобрена после рецензирования 21.08.2024  
Принята к печати 29.09.2024*

*Received 29.05.2024  
Approved after reviewing 21.08.2024  
Accepted 29.09.2024*



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-738-744

УДК 53.087:504.064.36

## Разработка волоконно-оптической системы для мониторинга геотехнических сооружений

Илларион Леонидович Никулин<sup>1</sup>, Юлия Ильинична Рофер<sup>2✉</sup>

<sup>1,2</sup> Пермский национальный исследовательский политехнический университет, Пермь, 614990, Российская Федерация

<sup>1</sup> nil@pstu.ru, <https://orcid.org/0000-0002-8496-7942>

<sup>2</sup> julia.rofer@yandex.ru✉, <https://orcid.org/0009-0002-5762-2647>

### Аннотация

**Введение.** В работе представлена концепция точечного амплитудного датчика регистрации смещения геотекстиля — синтетической ткани, армирующей геотехнические сооружения, подобные дамбе. Применение систем непрерывного контроля состояния строительной конструкции, основанных на идеи «сумного» геотекстиля, может значительно повысить безопасность объекта, предупреждая о необходимости проведения внеплановых ремонтных работ, возникновении аварийной ситуации и необходимости срочного прекращения эксплуатации объекта, эвакуации персонала или населения. Оценены возможности существующих технических решений датчиков смещения. Известно, что существующие системы мониторинга, использующие датчики на волоконных брэгговских решетках, не применимы в случае с геотекстилем. Это обусловлено большой податливостью грунта и практическим отсутствием в грунте упругой деформации. Кроме того, датчики на волоконных брэгговских решетках значительно дороже в производстве по сравнению с телекоммуникационным оптическим волокном.

**Метод.** Одномодовое волокно в чувствительном элементе образует одну или несколько петель, зажатых между подвижными упорами, прикрепленными к корпусу и к подвижному активатору. При макроизгибе армирующего оптоволокна происходит нарушении полного внутреннего отражения, что приводит к амплитудной модуляции излучения. Макроизгиб пропорционален смещению активатора, прикрепленного к геотекстилю. В работе приведены конструкция, размеры чувствительного элемента и математические соотношения размеров и характеристик элементов конструкции для обработки сигнала. Модель датчика реализована из ABS-пластика и оптоволокна Corning SMF-28. **Основные результаты.** Экспериментальная установка для проверки предложенной концепции реализует контролируемое смещение активатора, ввод и вывод излучения. Определены зависимости выходной мощности от диаметра изгиба оптоволокна в интервале от 25 до 11 мм и смещения в пределах до 14 мм при длине волны излучения 1550 нм. Показано, что полученные зависимости монотонны, на них имеются квазилинейные участки. Полученные на графиках перегибы при малом диаметре изгиба оптоволокна возникают в результате интенсивного выхода излучения из сердцевины в оболочку и рассеяния в ней, а при большом диаметре — из-за малых изгибных потерь. **Обсуждение.** Проведенные исследования показали, что предложенный датчик позволяет надежно фиксировать смещение до 0,5 мм. Результаты обладают хорошей повторяемостью. Отметим, что датчик уступает по точности регистрации смещений грунта, но по стоимости на порядок дешевле датчиков на волоконных брэгговских решетках.

### Ключевые слова

волоконно-оптический датчик, амплитудный датчик, датчик смещения, мониторинг строительных сооружений, умный геотекстиль, геотехника

**Ссылка для цитирования:** Никулин И.Л., Рофер Ю.И. Разработка волоконно-оптической системы для мониторинга геотехнических сооружений // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 738–744. doi: 10.17586/2226-1494-2024-24-5-738-744

## Development of a fiber-optic system for monitoring geotechnical structures

Illarion L. Nikulin<sup>1</sup>, Yulia I. Rofer<sup>2</sup>✉

<sup>1,2</sup> Perm National Research Polytechnic University, Perm, 614990, Russian Federation

<sup>1</sup> nil@pstu.ru, <https://orcid.org/0000-0002-8496-7942>

<sup>2</sup> julia.rofer@yandex.ru✉, <https://orcid.org/0009-0002-5762-2647>

### Abstract

The paper presents the concept of a point amplitude sensor for the registration of displacement of geotextile, a synthetic fabric that is used to reinforce geotechnical structures such as a dam. The implementation of a system for continuous monitoring of the structural condition of a building based on the concept of a “smart” geotextile has the potential to significantly enhance the safety of the structure. Such a system could provide early warning of the necessity for unscheduled repairs, the occurrence of an emergency situation, and the need for the immediate cessation of building operations, evacuation of personnel or population. The capabilities of existing technical solutions for displacement sensors have been evaluated. It is not feasible to apply existing monitoring systems utilizing fiber Bragg Grating Sensors (FBG) in the context of geotextile. This is due to the greater pliability of the soil which exhibits minimal elastic deformation. In addition, FBG sensors are much more expensive in production compared to telecommunication optical fiber. The single-mode fiber which constitutes the sensing element, forms one or more loops that are placed between movable stops that are attached to the sensor body and to the movable activator. At the point of macro bending of the reinforcing fiber, the phenomenon of total internal reflection is disrupted, which in turn gives rise to amplitude modulation of the radiation. The macro bending is proportional to the displacement of the activator attached to the geotextile. This paper presents the design, dimensions and mathematical relationships of the sensing element as well as the dimensions and characteristics of the design elements for signal processing. The sensor model is constructed from ABS plastic and fiber Corning SMF-28. An experimental setup was constructed to test the proposed concept which involved controlling the displacement of the activator, the input and output of radiation. The dependences of the output power on the fiber bending diameter, ranging from 25 to 11 mm, and the displacement, up to 14 mm, at a radiation wavelength of 1550 nm, were determined. It was demonstrated that the obtained dependences were monotonic and exhibited quasi-linear plots. The kinks at the small diameter of the fiber bend are caused by two factors: the intensive radiation output from the core to the cladding and scattering within it; and at the large diameter, they are due to small bending losses. The conducted studies have demonstrated that the sensor is capable of reliably detecting displacements up to 0.5 mm. The results exhibited good repeatability. The proposed sensor demonstrated inferior accuracy compared to FBG sensors. Conversely, at comparable accuracy of ground displacement registration, the proposed sensor was observed to be an order of magnitude more cost-effective than FBG sensors.

### Keywords

fiber optic sensor, amplitude sensor, displacement sensor, monitoring of building structures, smart geotextile, geotechnics

**For citation:** Nikulin I.N., Rofer Yu.I. Development of a fiber-optic system for monitoring geotechnical structures. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 738–744 (in Russian). doi: 10.17586/2226-1494-2024-24-5-738-744

### Введение

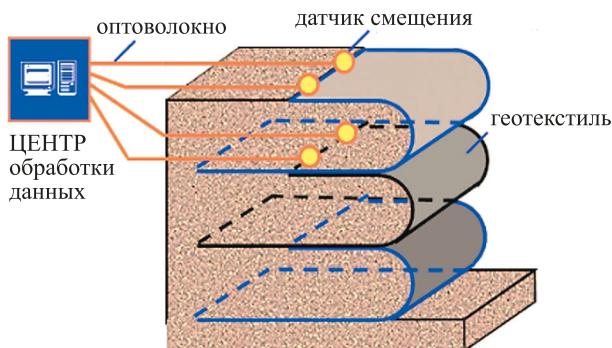
Согласно определению «Международного общества геосинтетики», геотекстиль или геосинтетические материалы представляют собой плоские, относительно непроницаемые, сделанные из синтетических или природных материалов полимерные полотна.

За последние несколько десятилетий значительно увеличилось применение геотекстиля в гражданском строительстве [1–3]. Армирование грунта геотекстилем позволяет за счет связи между арматурой и грунтом создать конструкции, способные принимать значительные нагрузки и увеличить несущую способность грунта без деформации [4]. К преимуществам использования геотекстиля можно отнести низкие затраты на производство и замену, простое с технической точки зрения устройство, компактность, простоту в транспортировке, быструю скорость монтажа, долгий срок службы, а также низкую чувствительность к воздействиям окружающей среды [5, 6]. Широко используемый в строительстве материал, а также тенденция создания «умных» материалов и строительных объектов вдохновили ученых на разработку «умного» геотекстиля.

Концепция «умного» геотекстиля (рис. 1) подразумевает внедрение датчиков и технологий мониторинга

в сам материал или в строительный объект. В самом простом случае можно закреплять волоконно-оптические датчики смещения на геотекстиле, который укладывается слоями вместе с грунтом, и при помощи оптоволокна соединять датчики с центром обработки данных, тем самым вести удаленный контроль состояния грунта [7]. Такая система мониторинга аналогична тем, что используются для мониторинга железнодорожных насыпей с помощью геосинтетических материалов, оснащенных датчиками [8], и укрепления откосов с помощью георешеток со встроенным оптоволокном [9], основанными на технологии рефлектометрии. Применение подобных систем непрерывного контроля состояния строительного объекта может значительно повысить его безопасность, предупреждая о необходимости проведения внеплановых ремонтных работ, либо о возникновении аварийной ситуации и необходимости срочного прекращения эксплуатации объекта или эвакуации персонала или населения [10–12].

В настоящее время для контроля состояния строительных конструкций применяют системы, в основе которых лежат датчики следующих типов [13]: тензометрические [14], акустические преобразователи [15], молекулярно-электронные [16] и волоконно-оптические [17]. Волоконно-оптические датчики разделяют



*Рис. 1. Схема армирования насыпи «умным» геотекстилем*  
*Fig. 1. Scheme of embankment reinforcement with “smart” geotextile*

на точечные [18], распределенные [19] и квазираспределенные [20]. Из них наиболее доступными являются волоконно-оптические датчики, основанные на использовании волоконных брэгговских решеток (ВБР). Волоконно-оптический датчик на основе ВБР создается как основа новой системы мониторинга зданий и сооружений, что позволяет контролировать основные параметры несущих строительных конструкций: деформацию, вибрацию и температуру [13].

Существующие системы контроля, использующие датчики на основе ВБР, не применяются для контроля геотекстиля. Это обусловлено тем, что грунт более податлив, чем кварцевое волокно, а также в грунте отсутствует упругая деформация. Кроме того, ВБР может записываться только в определенных (фоточувствительных) оптических волокнах. Как правило, они дополнительно легируются, а потому значительно дороже в производстве по сравнению с телекоммуникационным оптическим волокном [21].

В настоящей работе рассматривается создание системы, которая потенциально может быть использована для мониторинга состояния геотекстиля в дисперсных грунтах, которые представляют собой совокупности твердых частиц элементов, между которыми есть структурные связи. К грунтам такого типа относят песок, глину, ил или торф<sup>1</sup>. Таким образом, волоконно-оптический датчик будет подвергаться постоянному влиянию агрессивной и нестабильной среды, что может привести к помутнению оптоволокна и повреждению датчика [22]. Применение столь точных дорогих датчиков и построенных на них систем мониторинга, которые по себестоимости будут сравнимы с самим геотехническим сооружением, представляется экономически невыгодным.

Целью настоящей работы является разработка волоконно-оптической системы для контроля смещения геотекстиля, которым армируется геотехническое сооружение.

## Концепция и реализация волоконно-оптического датчика для мониторинга

Одним из основных способов защиты волоконно-оптических датчиков и создания необходимой связи между геотекстилем и датчиками является правильный подбор метода производства и внедрения системы [23–25], так как неправильная установка датчиков может запускать механизмы передачи напряжения от геотекстиля к сердцевине оптоволокна [25]. Сформулируем требования к разрабатываемому чувствительному элементу и системе мониторинга в целом. Конструкция датчика должна обеспечивать надежное измерение смещений геотекстиля порядка 1 мм. Именно величина смещения свидетельствует об опасной деформации сооружения, предупреждая о необходимости проведения ремонтных работ.

Отметим особенности контролируемой системы: геотекстиль обладает значительной жесткостью при растяжении и нулевой при сжатии; в дисперсном грунте доминируют пластические деформации, упругие — практически отсутствуют. Из этого следует, что сокращение деформации геотехнического сооружения со временем и связанное с ним смещение контролируемого конца геотекстиля влево (рис. 1) представляется нереалистичным. Таким образом, разработанный датчик должен фиксировать только увеличение смещения, при этом скорость смещения невелика.

Конструкция должна обладать простотой монтажа чувствительного элемента к полотну геотекстиля и к системе измерения. Схожие по назначению и основанные на рефлектометрии системы мониторинга [8, 9] имеют недостаток, в них чувствительный элемент (оптоволокно) встраивается в геотекстиль, что делает его производство более трудоемким. При этом геотекстиль подвержен риску повреждения, учитывая, что при механическом воздействии можно сломать оптическое волокно, и в результате геотекстиль будет непригоден для использования.

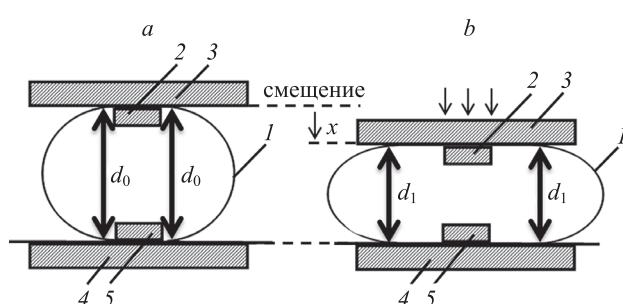
Отметим необходимость невысокой стоимости волоконно-оптических датчиков и всей системы измерения в целом, что должно обеспечить применение подобных систем мониторинга без значительного удорожания геотехнического сооружения.

К дополнительным требованиям можно отнести сохранение надежности конструкции на протяжении длительного времени (годов и десятилетий) и экологичность [26]. Эти требования обеспечиваются применением влагостойких волоконных кабелей, герметичностью волоконно-оптического датчика, гидрофобными материалами корпуса, а также применением оптоволокон, длительно сохраняющим оптические характеристики. Необходимо учесть, что датчик будет находиться далеко от источника приема излучения, поэтому его работа должна осуществляться в окнах прозрачности оптоволокна на длине волны  $\lambda = 1550$  нм.

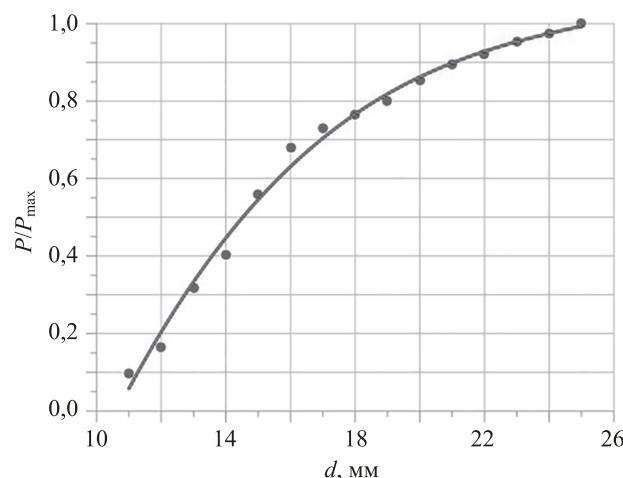
В основе концепции текущей разработки лежит известный факт зависимости пропускаемой мощности излучения при макроскопическом изгибе оптического волокна [27]. Амплитудная модуляция применена в датчиках вибрации [28, 29].

<sup>1</sup> ГОСТ 25100-2011 Грунты. Классификация. Введен 01.01.2013. М.: Изд-во стандартов, 2013. 44 с.

Чувствительный элемент разработанного волоконно-оптического датчика представляет собой участок волоконного световода, выполненный в виде одной или нескольких петель, закрепленных на основании корпуса датчика, которое прикрепляется к контролируемому объекту. Принципиальная схема крепления показана на рис. 2. Оптическое волокно закреплено между коротких и удлиненных упоров, которые служат для обеспечения контролируемой деформации в виде прямых участков в закрепленной части и полуколец диаметром  $d$  в незакрепленной. Экспериментально установлено, что для оптического волокна SMF-28 и длине волны излучения  $\lambda = 1550$  нм, при диаметре изгиба меньшем, чем  $d_0 = 25$  мм, излучение начинает покидать световод и происходит падение мощности. При смещении упоров кривизна оптоволокна уменьшается до диаметра  $d_1$  (рис. 2, *b*), которая приводит к нарушению полного внутреннего отражения, и, как следствие, выходу излучения из волокна и потере прошедшей мощности. По изменению мощности излучения можно судить о диаметре изгиба волокна. Полученная зависимость для оптоволокна SMF-28 при длине волны  $\lambda = 1550$  нм показана на рис. 3.



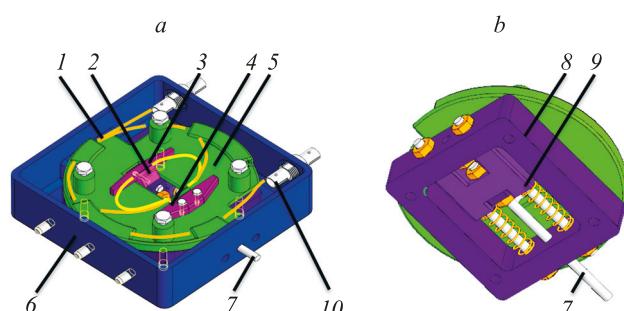
*Рис. 2. Схема крепления оптоволокна (а) и его деформирования (б): 1 — оптическое волокно; 2, 3 — подвижные упоры; 4, 5 — неподвижные упоры*  
*Fig. 2. Scheme of fiber attachment (a) and its deformation (b): 1 — optical fiber; 2, 3 — movable stops; 4, 5 — fixed stops*



*Рис. 3. Зависимость относительной средней проходящей мощности  $P/P_{\max}$  от диаметра изгиба  $d$*   
*Fig. 3. Dependence of the relative average passing power  $P/P_{\max}$  vs. the bending diameter  $d$*

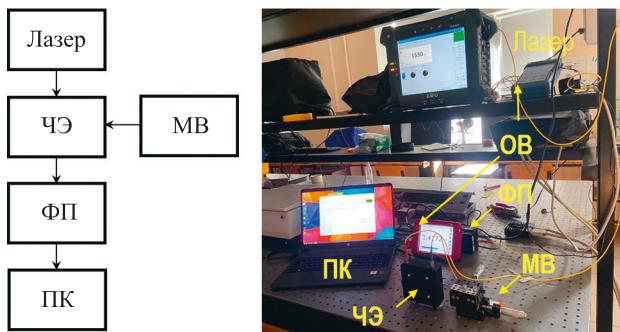
Схема разработанной волоконно-оптической системы представлена на рис. 4. Излучение от источника направляется к чувствительному элементу по оптоволокну 1, устойчивому к изгибам. Переход от оптоволокна к чувствительному элементу осуществляется благодаря оптической розетке 10, с помощью которой происходит вывод сигнала из чувствительного элемента. Чувствительный элемент находится в корпусе датчика 6. Волокно располагается на круглом столе 5, который предотвращает его попадание в зону движения каретки и пружин. Оптоволокно внутри чувствительного элемента образует две части: передающую и чувствительную. В передающей части излучение подводится к чувствительной и отводится от нее. Чувствительная часть представляет собой одну или несколько петель оптоволокна, которые размещены между упорами 5 и 4. Упор 4 жестко закреплен на круглом столе, а подвижные упоры 2 и 3 образуют крепление для волокна, присоединенное к подвижной части волоконно-оптического датчика.

В подвижной части активатор 7 одним концом соединяется с контролируемым объектом, а другим — с кареткой 9. Рама 8 обеспечивает соединение подвижной и неподвижной частей. Деформация на измеряемом объекте приводит в движение активатор 7, а с ним каретку 9 и упоры 2 и 3, тем самым уменьшая кривизну оптоволокна. Излучение, прошедшее через чувствительный элемент, распространяется далее по световоду и попадает на фотоприемник. Сигнал с фотоприемника обрабатывается с помощью разработанной программы на персональный компьютер. Модель разработанного точечного амплитудного волоконно-оптического датчика выполнена в программе АСКОН КОМПАС 3D и напечатана на 3D-принтере из ABS-пластика.



*Рис. 4. Схема чувствительного элемента датчика смещения: вид в корпусе сверху (а) и без корпуса снизу (б).*  
*1 — оптоволокно, чувствительное к изгибам; 2, 3 и 4 — подвижные и неподвижный упоры (рис. 1); 5 — неподвижный упор, круглый стол; 6 — корпус датчика; 7 — активатор; 8 — рама; 9 — подвижная каретка, передающая смещение с активатора к подвижным упорам 2 и 3; 10 — оптические розетки*

*Fig. 4. Diagram of the sensitive element of the displacement sensor: view from the top (a) and from the bottom without sensor body (b). 1 — bend-sensitive fiber; 2, 3 and 4 — movable and fixed stops (equivalent to those in Fig. 1); 5 — fixed stop, round table; 6 — sensor body; 7 — activator; 8 — frame; 9 — movable carriage, transmitting displacement from the activator to movable stops 2 and 3; 10 — optical sockets*



*Рис. 5. Принципиальная схема экспериментальной установки (а) и ее фотография (б): ЧЭ — чувствительный элемент; ФП — фотоприемник; ПК — персональный компьютер (блок обработки информации); МВ — микрометрический винт, подающий заданное смещение на ЧЭ; ОВ — оптическое волокно*

*Fig. 5. Schematic diagram of the experimental setup (a) and photograph (b): ЧЭ — sensitive element; ФП — photodetector; ПК — personal computer (information processing unit); МВ — micrometric screw that supplies a given displacement to the sensitive element; ОВ — optical fiber*

Экспериментальная установка (рис. 5, б) включает источник электромагнитного излучения EXFO FTB-500, разработанный волоконно-оптический датчик, фотоприемник Thorlabs PM200 и персональный компьютер для обработки данных. Схема подключения показана на рис. 5, а.

### Экспериментальные результаты

Экспериментальные результаты получены для длины волны  $\lambda = 1550$  нм, выходная мощность источника излучения  $P_{\max} = 5$  мкВт, частота опроса фотоприемника  $v = 95$  Гц. На рис. 6 показана зависимость относительной проходящей мощности  $P/P_{\max}$  от перемещения  $x$  микрометрического винта, связанного с диаметром изгиба волокна  $d$  (рис. 1), соотношением

$$x = d_0 - d,$$

где  $d_0$  — минимальный диаметр изгиба оптоволокна, при котором не возникает потерь проходящего излучения. Влияние шума источника излучения и фотоприемника характеризуется величиной относительной среднеквадратичной ошибки

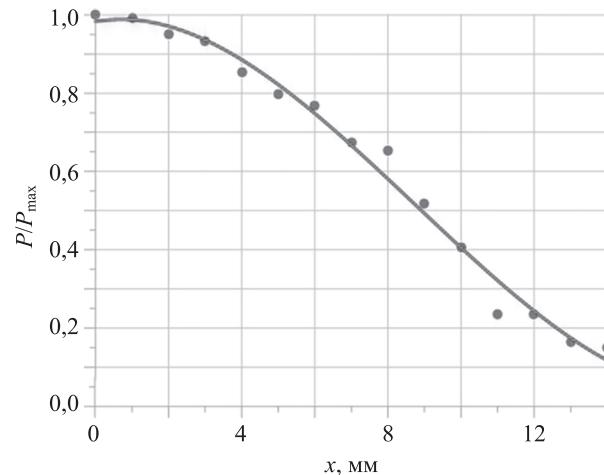
$$\delta P = \frac{\Delta P}{\langle P \rangle},$$

где  $\langle P \rangle$  — средняя мощность, полученная по формуле

$$\langle P \rangle = \frac{1}{n} \sum_{i=1}^n P_i,$$

где  $P_i$  — мощность при  $i$ -ом измерении;  $n$  — фиксированное число последовательных измерений  $n = 100$ ;  $\Delta P$  — среднеквадратичная ошибка, рассчитанная в виде:

$$\Delta P = \sqrt{\frac{\sum_{i=1}^n (P_i - \langle P \rangle)^2}{n(n-1)}}.$$



*Рис. 6. Зависимость смещения  $x$  от относительной средней проходящей мощности  $P/P_{\max}$*

*Fig. 6. Dependence of the displacement  $x$  vs. the relative average passing power  $P/P_{\max}$*

На рис. 6 видно, что зависимость выходной мощности от диаметра изгиба оптоволокна монотонна, но имеет перегибы при  $d_{low} = 14$  мм и  $d_{high} = 23$  мм. Это объясняется тем, что при малых диаметрах изгиба оптоволокна ( $d < d_{low}$ ) происходит нарушение полного отражения, в результате весь свет, передаваемый по оптоволокну, из сердцевины уходит в оболочку, а при больших ( $d > d_{high}$ ) — свет только начинает уходить из сердцевины в оболочку.

Величина шума составляет около 2 мкВт и при малых мощностях может влиять на результаты измерений, но она постоянна по абсолютной величине. Это указывает на то, что чувствительный элемент не является источником шума; т. е. вклад в шум дают только источник и приемник излучения. Эксперименты с другими более мощными источниками показали хорошую повторяемость результатов и значительно меньший относительный уровень шума. В работе представлены результаты эксперимента, в котором использовался менее мощный источник, который имитирует удаленность волоконно-оптического датчика и возможность измерения в неидеальных условиях. Таким образом, разработанная конструкция отвечает предполагаемым требованиям и может использоваться для определения смещения.

### Заключение

Разработан и реализован вариант точечного амплитудного волоконно-оптического датчика контроля смещения, который применим для контроля состояния геотекстиля. Проведенные измерения показали, что датчик позволяет надежно фиксировать смещение до 0,5 мм. Результаты обладают хорошей повторяемостью. Разработанный датчик значительно уступает в точности подобным датчикам, основанным на брэгговских решетках и способным измерять микронные смещения. Однако этой точности достаточно для контроля смещений грунта, кроме того, разработанный датчик на

порядок дешевле датчиков на волоконных брэгговских решетках, что обеспечивает его перспективность.

Дальнейшие направления развития исследования связаны с применением излучения других длин волн, их комбинации, а также способов герметизации дат-

чика. На следующем этапе работы планируется проверить работоспособность предложенной конструкции на экспериментальной установке, в которой он будет регистрировать смещение геотекстиля, зажатого между двумя слоями дисперсного грунта.

## Литература

- Touze-Foltz N., Bannour H., Barral C., Stoltz G. A review of the performance of geosynthetics for environmental protection // *Geotextiles and Geomembranes*. 2016. V. 44. P. 656–672. <https://doi.org/10.1016/j.geotexmem.2016.05.008>
- Obsharova A.V., Grishina A.S. Effect of the fiber reinforcement on the mechanical properties of clay soils, including properties under conditions of seasonal freezing and thawing // *Journal of Physics: Conference Series*. 2021. V. 1928. P. 012067. <https://doi.org/10.1088/1742-6596/1928/1/012067>
- Анферов Е.П., Гришина А.С., Смирнов Р.С. Исследование возможного применения волокнистых отходов в качестве армирующих волокон для создания эффективных геотехнических конструкций // Вестник Пермского национального исследовательского политехнического университета. Прикладная экология. 2018. № 1(29). С. 168–177. <https://doi.org/10.15593/2409-5125/2018.01.13>
- Пономарев А.Б., Офрихтер В.Г. Анализ и проблемы исследований геосинтетических материалов в России // Вестник Пермского национального исследовательского политехнического университета. Строительство и архитектура. 2013. № 2. С. 68–73.
- Li J., Cui X.Z., Jin Q., Su J.W., Cui S.Q., Wang Y.L. Laboratory investigation of the durability of a new smart geosynthetic material // *Construction and Building Materials*. 2018. V. 169. P. 28–33. <https://doi.org/10.1016/j.conbuildmat.2018.02.187>
- Wang Z., Richwien W. A study of soil-reinforcement interface friction // *Journal of Geotechnical and Geoenvironmental Engineering*. 2002. V. 128. N 1. P. 92–94. [https://doi.org/10.1061/\(asce\)1090-0241\(2002\)128:1\(92\)](https://doi.org/10.1061/(asce)1090-0241(2002)128:1(92))
- Wang B.-J., Li K., Shi B., Wei G.-Q. Test on application of distributed fiber optic sensing technique into soil slope monitoring // *Landslides*. 2009. V. 6. N 1. P. 61–68. <https://doi.org/10.1007/s10346-008-0139-y>
- Nöther N. Distributed fiber sensors in river embankments: advancing and implementing the brillouin optical frequency domain analysis. Berlin, Germany: BAM-Dissertationsreihe, 2010. 143 p.
- Hong C.Y., Yin J.H., Zhang Y.F. Deformation monitoring of long GFRP bar soil nails using distributed optical fiber sensing technology // *Smart Materials and Structures*. 2016. V. 25. N 8. P. 085044. <https://doi.org/10.1088/0964-1726/25/8/085044>
- Abedi M., Kiran Sanivada U., Ali Mirian S., Hassanshahi O., Al-Jabri K., Gomes Correia A., Lourenço P.B., Fangueiro R. A self-sensing and self-heating planar braided composite for smart civil infrastructures reinforcement // *Construction and Building Materials*. 2023. V. 387. P. 131617. <https://doi.org/10.1016/j.conbuildmat.2023.131617>
- Hatami K., Hassanikhah A., Yazdani H., Grady B.P. Tensoresistive PVC coating for sensor-enabled geogrids // *Journal of Nanomechanics and Micromechanics*. 2014. V. 4. N 4. P. A4013016. [https://doi.org/10.1061/\(asce\)nm.2153-5477.0000070](https://doi.org/10.1061/(asce)nm.2153-5477.0000070)
- Fathi A., Hatami K., Grady B.P. Effect of carbon black structure on low-strain conductivity of polypropylene and low-density polyethylene composites // *Polymer Engineering and Science*. 2012. V. 52. N 3. P. 549–556. <https://doi.org/10.1002/pen.22115>
- Калижанова А.У., Кашаганова Г.Б., Козбакова А.Х., Едилхан Д., Амиргалиева Ж.Е., Оразбеков Ж. Анализ и исследование существующего опыта проектирования и использования различных современных волоконно-оптических датчиков для контроля состояния механических и строительных конструкций // Вестник казахской академии транспорта и коммуникаций им. М. Тынышпаева. 2021. № 3(118). С. 112–123. <https://doi.org/10.52167/1609-1817-2021-118-3-110-123>
- Костиков К., Чукан Й. Тензометрические датчики силы // Компоненты и Технологии. 2010. № 1(102). С. 16–18.
- Taranov M.A., Gorshkov B.G., Alekseev A.E., Konstantinov Yu.A., Turov A.T., Barkov F.L., Wang Z., Zhao Z., Zan M.S.D., Kolesnichenko E.V. Optical reflectometry, metrology, and sensing. present and future (Review). *Instruments and Experimental*

## References

- Touze-Foltz N., Bannour H., Barral C., Stoltz G. A review of the performance of geosynthetics for environmental protection. *Geotextiles and Geomembranes*, 2016, vol. 44, pp. 656–672. <https://doi.org/10.1016/j.geotexmem.2016.05.008>
- Obsharova A.V., Grishina A.S. Effect of the fiber reinforcement on the mechanical properties of clay soils, including properties under conditions of seasonal freezing and thawing. *Journal of Physics: Conference Series*, 2021, vol. 1928, pp. 012067. <https://doi.org/10.1088/1742-6596/1928/1/012067>
- Anferov E., Grishina A., Smirnov R. Research of possible application of fibrous waste as reinforcing fibres for the creation of efficient geotechnical constructions. *PNRPU. Applied ecology. Urban development*, 2018, no. 1(29), pp. 168–177. (in Russian). <https://doi.org/10.15593/2409-5125/2018.01.13>
- Ponomarev A.B., Ofrikhter V.G. Analysis and problems of geosynthetic material application in Russian Federation. *Bulletin of Perm National Research Polytechnic University. Construction and Architecture*, 2013, no. 2, pp. 68–73. (in Russian)
- Li J., Cui X.Z., Jin Q., Su J.W., Cui S.Q., Wang Y.L. Laboratory investigation of the durability of a new smart geosynthetic material. *Construction and Building Materials*, 2018, vol. 169, pp. 28–33. <https://doi.org/10.1016/j.conbuildmat.2018.02.187>
- Wang Z., Richwien W. A study of soil-reinforcement interface friction. *Journal of Geotechnical and Geoenvironmental Engineering*, 2002, vol. 128, no. 1, pp. 92–94. [https://doi.org/10.1061/\(asce\)1090-0241\(2002\)128:1\(92\)](https://doi.org/10.1061/(asce)1090-0241(2002)128:1(92))
- Wang B.-J., Li K., Shi B., Wei G.-Q. Test on application of distributed fiber optic sensing technique into soil slope monitoring. *Landslides*, 2009, vol. 6, no. 1, pp. 61–68. <https://doi.org/10.1007/s10346-008-0139-y>
- Nöther N. *Distributed fiber sensors in river embankments: advancing and implementing the brillouin optical frequency domain analysis*. Berlin, Germany: BAM-Dissertationsreihe, 2010, 143 p.
- Hong C.Y., Yin J.H., Zhang Y.F. Deformation monitoring of long GFRP bar soil nails using distributed optical fiber sensing technology. *Smart Materials and Structures*, 2016, vol. 25, no. 8, pp. 085044. <https://doi.org/10.1088/0964-1726/25/8/085044>
- Abedi M., Kiran Sanivada U., Ali Mirian S., Hassanshahi O., Al-Jabri K., Gomes Correia A., Lourenço P.B., Fangueiro R. A self-sensing and self-heating planar braided composite for smart civil infrastructures reinforcement. *Construction and Building Materials*, 2023, vol. 387, pp. 131617. <https://doi.org/10.1016/j.conbuildmat.2023.131617>
- Hatami K., Hassanikhah A., Yazdani H., Grady B.P. Tensoresistive PVC coating for sensor-enabled geogrids. *Journal of Nanomechanics and Micromechanics*, 2014, vol. 4, no. 4, pp. A4013016. [https://doi.org/10.1061/\(asce\)nm.2153-5477.0000070](https://doi.org/10.1061/(asce)nm.2153-5477.0000070)
- Fathi A., Hatami K., Grady B.P. Effect of carbon black structure on low-strain conductivity of polypropylene and low-density polyethylene composites. *Polymer Engineering and Science*, 2012, vol. 52, no. 3, pp. 549–556. <https://doi.org/10.1002/pen.22115>
- Kalizhanova A., Kashaganova G., Kozbakova A., Edilkhan D., Amirkaliyeva Zh., Orazbekov Zh. Analysis and research of the existing experience in the design and use of various modern fiber-optic sensors for monitoring the condition of mechanical and building structures. *The Bulletin of Kazakh Academy of Transport and Communications named after M. Tynyshpayev*, 2021, no. 3(118), pp. 112–123. (in Russian). <https://doi.org/10.52167/1609-1817-2021-118-3-110-123>
- Kostikov K., Chukan I. Strain gauge force transducers. *Components & Technologies*, 2010, no. 1(102), pp. 16–18. (in Russian)
- Taranov M.A., Gorshkov B.G., Alekseev A.E., Konstantinov Yu.A., Turov A.T., Barkov F.L., Wang Z., Zhao Z., Zan M.S.D., Kolesnichenko E.V. Optical reflectometry, metrology, and sensing. present and future (Review). *Instruments and Experimental*

- present and future (Review) // Instruments and Experimental Techniques. 2023. V. 66. N 5. P. 713–729. <https://doi.org/10.1134/s0020441223050238>
16. Шабалина А.С., Зайцев Д.Л., Егоров Е.В., Егоров И.В., Антонов А.Н., Бугаев А.С., Агафонов В.М., Криштоп В.Г. Молекулярно-электронные преобразователи в современных измерительных приборах // Успехи современной радиоэлектроники. 2014. № 9. С. 33–45.
  17. Вялышев А.И., Добров В.М., Долгов А.А., Бутов О.В. Плещков А.Ю. Волоконно-оптические датчики для контроля параметров состояния объектов и окружающей среды в задачах мониторинга // Природообустройство. 2014. № 3. С. 32–37.
  18. Волоконно-оптические датчики: вводный курс для инженеров и научных работников / под ред. Э. Удда; пер. с англ. М.: Техносфера, 2008. 520 с.
  19. Листвин А.В., Листвин В.Н. Рефлектометрия оптических волокон. М.: ЛЕСАРарт, 2005. 208 с.
  20. Кульчин Ю.Н. Распределенные волоконно-оптические датчики и измерительные сети. Владивосток: Дальнавака, 1999. 283 с.
  21. Кащаганова Г.Б., Касимов А.О. Технология изготовления волоконных брэгговских решеток // Труды Международного симпозиума «Надежность и качество». Т. 2. 2015. С. 106–109.
  22. Губская О.А., Плут М.Н., Спиридонов О.Р., Фатьянова Е.В. Анализ внешних факторов, влияющих на работоспособность волоконно-оптических систем передач // Известия ТулГУ. Технические науки. 2020. № 5. С. 102–107.
  23. Guangqing W., Bin S., Xiaokui Y., Chunde P., Youqun Z., Baojun W. BOTDR based distributed strain test on bored pile buried in complicated geological ground // Journal of Engineering Geology. 2008. V. 16. N 6. P. 826–832.
  24. Piao C.D., Shi B., Gao L. Characteristics and application of BOTDR in distributed detection of pile foundation // Advanced Materials Research. 2011. V. 163–167. P. 2657–2665. <https://doi.org/10.4028/www.scientific.net/amr.163-167.2657>
  25. Liu W., Wang H., Zhou Z., Xing X., Cao D., Jiang Z. Optical fiber-based sensors with flexible encapsulation for pavement behavior monitoring // Structural Control and Health Monitoring. 2015. V. 22. N 2. P. 301–313. <https://doi.org/10.1002/stc.1674>
  26. Abedi M., Figueiro R., Correia A.G., Shayanfar J. Smart geosynthetics and prospects for civil infrastructure monitoring: A comprehensive and critical review // Sustainability. 2023. V. 15. N 12. P. 9258. <https://doi.org/10.3390/su15129258>
  27. Бурдышева О.В., Сушко Д.Н., Шолгин Е.С., Васильев А.Б., Дроздов И.Р., Никулин И.Л. Разработка волоконно-оптического датчика показателя преломления на макроизгибе // Вестник современной науки. 2015. № 5. С. 18–21.
  28. Бурдышева О.В., Никулин И.Л. Амплитудный волоконно-оптический датчик вибрации // Фotonika. 2019. Т. 13. № 1. С. 80–85. <https://doi.org/10.22184/FRos.2019.13.1.80.85>
  29. Никулин И.Л., Бурдышева О.В. Волоконно-оптическое устройство регистрации вибраций. Патент RU179547U1. Бюл. 2018. № 14.
  - Techniques, 2023, vol. 66, no. 5, pp. 713–729. <https://doi.org/10.1134/s0020441223050238>
  16. Shabalina A.S., Zajcev D.L., Egorov E.V., Egorov I.V., Antonov A.N., Bugaev A.S., Agafonov V.M., Krishtop V.G. Modern measuring instruments based on molecular electronic transducers. Journal Achievements of Modern Radioelectronics, 2014, no 9, pp. 33–45. (in Russian)
  17. Vyalyshev A.I., Dobrov V.M., Dolgov A.A., Butov O.V., Pleshakov A.Yu. Fiber-optical sensors for the control of parameters of the state of objects and environment in the tasks of monitoring. Prirodoobustroystvo, 2014, no. 3, pp. 32–37. (in Russian)
  18. Fiber Optic Sensors. An Introduction for Engineers and Scientists. Ed. by E. Udd. Wiley, 2006, 476 p.
  19. Listvin A.V., Listvin V.N. Optical Fiber Reflectometry. Moscow, LESARart, 2005, 208 p. (in Russian)
  20. Kulchin Iu.N. Distributed Fiber Optic Sensors and Measurement Networks. Vladivostok, Dalnauka, 1999, 283 p. (in Russian)
  21. Kashaganova G.B., Kasimov A.O. Fiber Bragg grating technology. Proc. of the International Symposium "Reliability and Quality". V. 2, 2015, pp. 106–109. (in Russian)
  22. Gubskaya O.A., Plut M.N., Spiridonov O.R., Fatyanova E.V. Analysis of external factors affecting the performance of fiber-optic transmission systems. Izvestiya Tula State University, 2020, no. 5, pp. 102–107. (in Russian)
  23. Guangqing W., Bin S., Xiaokui Y., Chunde P., Youqun Z., Baojun W. BOTDR based distributed strain test on bored pile buried in complicated geological ground. Journal of Engineering Geology, 2008, vol. 16, no. 6, pp. 826–832.
  24. Piao C.D., Shi B., Gao L. Characteristics and application of BOTDR in distributed detection of pile foundation. Advanced Materials Research, 2011, vol. 163–167, pp. 2657–2665. <https://doi.org/10.4028/www.scientific.net/amr.163-167.2657>
  25. Liu W., Wang H., Zhou Z., Xing X., Cao D., Jiang Z. Optical fiber-based sensors with flexible encapsulation for pavement behavior monitoring. Structural Control and Health Monitoring, 2015, vol. 22, no. 2, pp. 301–313. <https://doi.org/10.1002/stc.1674>
  26. Abedi M., Figueiro R., Correia A.G., Shayanfar J. Smart geosynthetics and prospects for civil infrastructure monitoring: A comprehensive and critical review. Sustainability, 2023, vol. 15, no. 12, pp. 9258. <https://doi.org/10.3390/su15129258>
  27. Burdysheva O.V., Sushko D.N., Sholgin E.S., Vasilev A.B., Drozdov I.R., Nikulin I.L. Development of a fiber optic refractive index sensor at a macrobend. Vestnik sovremennoj nauki, 2015, no. 5, pp. 18–21. (in Russian)
  28. Burdysheva O.V., Nikulin I.L. Amplitude fiber-optic vibration sensor. Photonics Russia, 2019, vol. 13, no. 1, pp. 80–85. (in Russian). <https://doi.org/10.22184/FRos.2019.13.1.80.85>
  29. Nikulin I.L., Burdysheva O.V. Fiber optic vibration recording device. Patent RU179547U1. 2018. (in Russian)

## Авторы

**Никулин Илларион Леонидович** — доктор технических наук, профессор, профессор, Пермский национальный исследовательский политехнический университет, Пермь, 614990, Российская Федерация, <https://orcid.org/0000-0002-8496-7942>, nil@psstu.ru

**Рофер Юлия Ильинична** — студент, Пермский национальный исследовательский политехнический университет, Пермь, 614990, Российская Федерация, <https://orcid.org/0009-0002-5762-2647>, julia.rofer@yandex.ru

Статья поступила в редакцию 24.06.2024  
Одобрена после рецензирования 02.08.2024  
Принята к печати 26.09.2024



## Authors

**Illarion L. Nikulin** — D.Sc., Full Professor, Perm National Research Polytechnic University, Perm, 614990, Russian Federation, <https://orcid.org/0000-0002-8496-7942>, nil@psstu.ru

**Yulia I. Rofer** — Student, Perm National Research Polytechnic University, Perm, 614990, Russian Federation, <https://orcid.org/0009-0002-5762-2647>, julia.rofer@yandex.ru

Received 24.06.2024

Approved after reviewing 02.08.2024

Accepted 26.09.2024

Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

## АВТОМАТИЧЕСКОЕ УПРАВЛЕНИЕ И РОБОТОТЕХНИКА AUTOMATIC CONTROL AND ROBOTICS

doi: 10.17586/2226-1494-2024-24-5-745-750  
УДК 681.51

### Управление нелинейными объектами с гаранцией нахождения регулируемой переменной в заданном множестве при возмущениях и помехах в измерениях

Сюэчэн Вэнь<sup>1✉</sup>, Игорь Борисович Фуртат<sup>2</sup>

<sup>1,2</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>2</sup> Институт проблем машиноведения Российской академии наук, Санкт-Петербург, 199178, Российская Федерация

<sup>1</sup> [xuecheng.wen@outlook.com](mailto:xuecheng.wen@outlook.com), <https://orcid.org/0000-0001-8676-6696>

<sup>2</sup> [cainenash@mail.ru](mailto:cainenash@mail.ru), <https://orcid.org/0000-0003-4679-5884>

#### Аннотация

**Введение.** Предложен новый алгоритм управления нелинейными объектами с гаранцией нахождения регулируемой переменной в заданном множестве в условиях параметрической неопределенности, внешних возмущений и высокочастотных помех в измерениях. **Метод.** Задача решена в два этапа. На первом этапе применен линейный фильтр низких частот для устранения высокочастотных составляющих в измеряемом сигнале. На втором этапе использовано преобразование координат, чтобы свести исходную задачу с ограничениями к задаче исследования на устойчивость по вход-состоянию новой системы без ограничений. **Основные результаты.** Разработан алгоритм обратной связи по выходу для нелинейных систем в условиях параметрической неопределенности, внешних возмущений и высокочастотных помех в измерениях. Выполнено моделирование в MATLAB/Simulink, результаты которого показали эффективность предложенного алгоритма. **Обсуждение.** Представленный алгоритм может эффективно решать задачи управления электроэнергетическими сетями и рядом других электромеханических систем при наличии помех в измерениях.

#### Ключевые слова

нелинейная система, возмущение, помеха, преобразование координат, устойчивость, робастное управление

#### Благодарности

Работа выполнена в Институте проблем машиноведения РАН при поддержке гранта Российского научного фонда № 23-41-00060.

**Ссылка для цитирования:** Вэнь С., Фуртат И.Б. Управление нелинейными объектами с гаранцией нахождения регулируемой переменной в заданном множестве при возмущениях и помехах в измерениях // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 745–750. doi: 10.17586/2226-1494-2024-24-5-745-750

### Control of nonlinear plants with a guarantee for the controlled signal to stay within a given set under disturbances and high-frequency measurement noises

Xuecheng Wen<sup>1✉</sup>, Igor B. Furtat<sup>2</sup>

<sup>1,2</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>2</sup> Institute of Problems of Mechanical Engineering of the Russian Academy of Sciences, Saint Petersburg, 199178, Russian Federation

<sup>1</sup> [xuecheng.wen@outlook.com](mailto:xuecheng.wen@outlook.com), <https://orcid.org/0000-0001-8676-6696>

<sup>2</sup> [cainenash@mail.ru](mailto:cainenash@mail.ru), <https://orcid.org/0000-0003-4679-5884>

#### Abstract

A new control algorithm for nonlinear plants is proposed, ensuring the controlled variable stays within a given set under conditions of parametric uncertainties, external disturbances and high-frequency noises in measurements. The

© Вэнь С., Фуртат И.Б., 2024

problem is solved in two stages. In the first stage, a low-pass filter is applied to eliminate high-frequency components in the measured controlled signal. In the second stage, a coordinate transformation represents the initial problem with given restrictions as an input-state stability analysis problem of a new system without constraints. An output feedback algorithm has been developed for uncertain nonlinear systems under conditions of parametric uncertainties, external disturbances, and high-frequency noise in measurements. Simulations in MATLAB/Simulink are given. The simulation results show the efficiency of the proposed algorithm. The proposed algorithm can effectively solve control problems for power systems or electromechanical systems in the presence of measurement noises.

### Keywords

nonlinear system, disturbance, noise, the change of coordinates, stability, robust control

### Acknowledgements

The work was carried out at the IPME RAS with the support of the Russian Science Foundation grant no. 23-41-00060.

**For citation:** Wen Xu., Furtat I.B. Control of nonlinear plants with a guarantee for the controlled signal to stay within a given set under disturbances and high-frequency measurement noises. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 745–750 (in Russian). doi: 10.17586/2226-1494-2024-24-5-745-750

## Введение

На практике системы управления всегда подвержены влиянию внешних помех. Например, в системах возбуждения генераторов электромагнитные помехи могут появляться в процессе переключения. Высокочастотные помехи возникают в сигналах измерения частоты вращения роторов генераторов. В условиях параметрической неопределенности и внешних помех разработка простых систем управления является важной задачей в теории и практике управления. Для их разработки в этих условиях предложено множество решений.

В [1–3] разработаны адаптивные наблюдатели с большим коэффициентом усиления в обратной связи. В переходном процессе значение коэффициента усиления выбирается большим, а в стационарном — уменьшается, чтобы частично решить проблему, описанную в работах [1, 2, 4], когда оценка производной наблюдателя может значительно превышать фактическое значение самой производной.

В [5, 6] предложен расширенный наблюдатель с большим коэффициентом усиления. Введены дополнительные динамические звенья для увеличения размерности модели с целью уменьшения чувствительности к шуму. В [7] использован линейный фильтр низких частот (ФНЧ) для снижения воздействия высокочастотного шума на выходной сигнал.

В настоящей работе рассматривается задача, когда измерению доступен только выходной сигнал объекта и присутствует высокочастотный шум в измерениях. Основываясь на работах [8, 9], предложен модифицированный алгоритм управления нелинейными объектами с гарантированием нахождения выходного сигнала в заданном множестве. Выполнен анализ недостатков применения методов управления, предложенных в [8], в условиях помех в измерениях. Представлен усовершенствованный алгоритм управления на основе линейного ФНЧ. Приведена иллюстрация примеров эффективности разработанного алгоритма в соответствии с полученными результатами моделирования.

## Постановка задачи

Рассмотрим нелинейную динамическую систему

$$Q(p)y(t) = kR_m(p)u(t) + f(y, t), \quad (1)$$

$$z(t) = y(t) + w(t), \quad (2)$$

где  $u \in \mathbb{R}$  — сигнал управления;  $y \in \mathbb{R}$  — неизмеряемый выходной сигнал;  $w \in \mathbb{R}$  — ограниченный шум;  $z \in \mathbb{R}$  — измеряемый сигнал;  $f \in \mathbb{R}$  — неизвестное ограниченное возмущение при условии, что  $|f(y, t)| \leq f$ ;  $s$  — комплексная переменная преобразования Лапласа;  $Q(s)$  и  $R_m(s)$  — нормированные полиномы, имеющие неизвестные параметры, порядки полиномов известны и равны  $n$  и  $m$ ;  $R_m(s)$  — гурвицевый полином;  $p = \frac{d}{dt}$  — оператор дифференцирования;  $k > 0$  — известный коэффициент. Объект управления (1) является минимально-фазовым. Выражение (2) представляет собой выходной сигнал с аддитивно наложенным шумом.

Цель работы — разработка закона управления, гарантирующего нахождение выходного сигнала  $y(t)$  объекта (1) в множестве

$$Y = \{y \in \mathbb{R}: g < y < \bar{g}\}, \quad (3)$$

где  $g(t)$  и  $\bar{g}(t)$  — непрерывно дифференцируемые функции,  $g(t)$ ,  $\bar{g}(t)$ ,  $\dot{g}(t)$ ,  $\ddot{g}(t)$  — ограничены для любого времени  $t$ . Функции  $g(t)$  и  $\bar{g}(t)$  могут выбираться разработчиками, исходя из требований к работе системы. Например, в задаче управления электрическим генератором [10–12] требуется поддержание частоты  $\omega(t)$  в заданных пределах  $\underline{\omega}(t) \leq \omega(t) \leq \bar{\omega}(t)$ .

## Метод решения. Основной результат

Для выделения сигнала  $y(t)$  из  $z(t)$ , рассмотрим линейный ФНЧ в виде:

$$\lambda \dot{\xi}(t) = \mathbf{G} \xi(t) + \mathbf{B} z(t), \quad \hat{y}(t) = \mathbf{L} \xi(t), \quad (4)$$

где  $\xi = [\xi_1, \xi_2, \dots, \xi_r]^T$ ,  $\mathbf{L} = [0, \dots, 0, 1]$ ,  $\mathbf{B} = [\sigma^{-1}, 0, \dots, 0]^T$ ,

$$\mathbf{G} = \begin{bmatrix} -\sigma^{-1} & 0 & 0 & \cdots & 0 & 0 \\ \sigma^{-1} & -\sigma^{-1} & 0 & \cdots & 0 & 0 \\ 0 & \sigma^{-1} & -\sigma^{-1} & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & \sigma^{-1} & -\sigma^{-1} \end{bmatrix},$$

$\sigma > 0$  и  $\lambda > 0$  — параметры фильтра;  $\mathbf{G}$  и  $\mathbf{B}$  — матрицы, имеющие соответствующие размерности;

$L$  — размерность матрицы равна  $1 \times r$ ;  $\xi$  — вектор состояния фильтра;  $\hat{y}(t)$  — оценка выходного сигнала,  $\Delta y(t) = \hat{y}(t) - y(t)$  — ошибка оценивания выходного сигнала.

Пусть шум  $w$  представлен мультигармоническим сигналом вида

$$w(t) = \sum_{i=1}^v A_i \sin(\omega_i t + \phi_i), \quad (5)$$

где  $A_i$ ,  $\omega_i$  и  $\phi_i$  — амплитуда, частота и фаза  $i$ -й гармоники. Согласно [7],  $\Delta y$  ограничено и удовлетворяет следующему неравенству

$$\overline{\lim}_{t \rightarrow \infty} |\Delta y| \leq \sum_{i=1}^v A_i \left( \prod_{j=1}^r \frac{1}{\sqrt{1 + \omega_j^2 \lambda^2 \sigma^2}} \right) + \delta, \quad (6)$$

где  $\delta > 0$  — достаточно малое число. Поскольку  $\Delta y$  представляет ошибку оценки и ограничено и если  $|\Delta y| < \min\left(\frac{\bar{g}(t) - \underline{g}(t)}{2}\right)$  то используется параметр  $a$  для гарантии нахождения сигнала  $\hat{y}(t)$  в более узком множестве. Таким образом,  $y(t)$  принадлежит  $\hat{Y}$ . Значит, если существуют такие  $a$ , что  $|\Delta y| \leq a < \min\left(\frac{\bar{g}(t) - \underline{g}(t)}{2}\right)$ , и закон управления  $u(t)$ , что

$$\hat{Y} = \{\hat{y} \in \mathbb{R}: \underline{g} + a < \hat{y} < \bar{g} - a\}, \quad (7)$$

то  $u(t)$  и фильтр (4) обеспечивают выполнение целевого условия (3).

**Замечание 1.** Выбор параметра  $a$  зависит от  $\Delta y$ . Первое слагаемое в правой части (6) описывает оценку качества подавления шума (5) ФНЧ, где величина оценки зависит от частот каждой гармоники  $\omega_i$  и срета  $\frac{1}{\lambda \sigma}$ . Второе слагаемое в (6) описывает искажение сигнала  $y$ , вызванное ФНЧ, и его величина зависит от  $\lambda$ . Уменьшение числа  $\lambda$  в (4) «сводит» динамический фильтр к статическому звену, а увеличение чисел  $r$  и  $\sigma$  — к уменьшению первого слагаемого в правой части (6), а значит, и к уменьшению величины  $a$ .

Задача гарантированного определения сигнала  $\hat{y}(t)$  в заданном множестве  $\hat{Y}$  преобразуется к задаче без ограничений, если воспользоваться преобразованием координат

$$\hat{y}(t) = \Phi(\varepsilon(t), t), \quad (8)$$

где  $\varepsilon(t) \in \mathbb{R}$  — непрерывно-дифференцируемая функция по времени  $t$ , удовлетворяющая следующим условиям:

- 1)  $g(t) + a < \Phi(\varepsilon, t) < \bar{g}(t) - a$  при  $t \geq 0$  и  $\varepsilon \in \mathbb{R}$ ;
- 2)  $\Phi(\varepsilon, t)$  — непрерывно-дифференцируемая функция по  $\varepsilon$  и  $t$ ,  $\frac{\partial \Phi(\varepsilon, t)}{\partial \varepsilon} > 0$  для любых  $t \geq 0$  и  $\varepsilon \in \mathbb{R}$ ;
- 3)  $\frac{\partial \Phi(\varepsilon, t)}{\partial t}$  — ограниченная функция для  $\varepsilon$  и  $t \geq 0$ .

Вычислив полную производную по времени функции  $\hat{y}(t)$  в (8), получим

$$\dot{\varepsilon} = \left( \frac{\partial \Phi(\varepsilon, t)}{\partial \varepsilon} \right)^{-1} \left( \dot{\hat{y}} - \frac{\partial \Phi(\varepsilon, t)}{\partial t} \right). \quad (9)$$

Приведем основной результат работы [8, теорема 1]. Пусть для преобразования (8) выполнены условия (1)–(3). Если существует такой закон управления  $u(t)$ , что решение (9) ограничено, то  $\hat{y}(t) \in \hat{Y}_a \subset \hat{Y}$ . Если при выбранном законе управления решения (9) не ограничены, то  $\hat{y}(t) \in \hat{Y}$ .

Пусть выбран закон управления так, что решение уравнения (9) ограничено, т. е.  $|\varepsilon(t)| < N$  при любом  $t$ , где  $0 < N < \infty$ . Тогда в силу преобразования (8) и условия (1) следует, что  $\hat{y}(t) \in \hat{Y}_a = \{\hat{y} \in \mathbb{R}: \underline{M}(t) < \hat{y}(t) < \bar{M}(t)\}$ , где  $\underline{M}(t) = \inf_{|\varepsilon| < N} \{\Phi(\varepsilon(t), t)\}$  и  $\bar{M}(t) = \sup_{|\varepsilon| < N} \{\Phi(\varepsilon(t), t)\}$  для любых  $t \geq 0$ . Поскольку (8) является взаимно однозначным отображением, то  $\underline{M}(t) < \bar{g}(t) - a$  и  $\bar{M}(t) > \underline{g}(t) + a$ , значит,  $\hat{Y}_a \subset \hat{Y}$ .

Пусть  $Q(s) = Q_m(s) + \Delta Q(s)$ .  $Q_m(s)$  является нормированным гурвицевым полиномом степени  $n$ . Следовательно,  $\deg \Delta Q(s) = n - 1$ . Найдем преобразование Лапласа от (4) и (1) в виде:

$$\hat{y}(s) = \frac{1}{(\lambda \sigma s + 1)^r} (y(s) + w(s)) + \frac{\lambda \sigma}{(\lambda \sigma s + 1)} \hat{y}(0), \quad (10)$$

$$y(s) = \frac{k R_m(s)}{Q_m(s)} u(s) - \frac{\Delta Q(s)}{Q_m(s)} y(s) + \frac{1}{Q_m(s)} f(s) + \epsilon(s), \quad (11)$$

где  $\epsilon(s)$  — экспоненциально затухающая функция, зависящая от ненулевых начальных условий  $y(t)$ .

Найдем обратные преобразования Лапласа от (10) и (11) и перепишем (9):

$$\dot{\varepsilon} = \left( \frac{\partial \Phi(\varepsilon, t)}{\partial \varepsilon} \right)^{-1} \left( \frac{k p R_m(p)}{\bar{Q}_m(p)} u(t) + \varphi(t) \right), \quad (12)$$

где  $\bar{Q}_m(p) = Q_m(p)(\lambda \sigma p + 1)^r$ ;  $Q_m(p)$  — нормированный гурвицев полином степени  $n$ ;  $\varphi(t) = -\frac{p \Delta Q(p)}{\bar{Q}_m(p)} \hat{y}(t) + \frac{\lambda \sigma}{\bar{Q}_m(p)} + \frac{p}{\bar{Q}_m(p)} f(y, t) + \frac{p}{(\lambda \sigma p + 1)^r} (w(t) + \epsilon(t)) + \frac{\lambda \sigma}{(\lambda \sigma p + 1)^r} \hat{y}(0) - \frac{\partial \Phi(\varepsilon, t)}{\partial t}$  — новое возмущение. Сигнал  $\hat{y}(t)$  из теоремы 1 ограничен.

Поскольку  $w(t)$  является ограниченным шумом и  $f(y, t)$  является неизвестным ограниченным возмущением, то имеем следующее неравенство  $|\varphi(t)| \leq \bar{\varphi}$ .

Введем закон управления:

$$u(t) = -\frac{Q_m(p)}{R_m(p)[p(\mu p + 1)^{p-1} + b\mu]} K \varepsilon(\hat{y}(t), t), \quad (13)$$

где  $p = \deg Q_m(p) - \deg R(p) > 1$ ;  $K > 0$  — константа;  $\mu > 0$  и  $b > 0$  — малые числа, которые выбираются так, что полином  $s(\mu s + 1)^{p-1} + b\mu$  является гурвицевым. С учетом (13), перепишем (12) в виде:

$$\dot{\varepsilon}(t) = \left( \frac{\partial \Phi(\varepsilon, t)}{\partial \varepsilon} \right)^{-1} \times \left( -k K \frac{p}{(\lambda \sigma p + 1)^r [p(\mu p + 1)^{p-1} + b\mu]} \varepsilon(t) + \varphi(t) \right). \quad (14)$$

**Теорема 2.** Пусть для преобразования (8) выполнены условия (1)–(3). Для заданных  $\lambda > 0$ ,  $\sigma > 0$ ,

$\mu > 0$  и  $b > 0$  существуют  $a > 0$ ,  $\sigma_0 > 0$  и  $\mu_0 > 0$  такие, что для  $\mu_0 > \mu$  полином  $s(\mu s + 1)^{p-1} + b\mu$  является гурвицевым, а также для  $\sigma_0 > \lambda\sigma$  выполнено  $|\Delta y| \leq a < \min\left(\frac{\bar{g}(t) - g(t)}{2}\right)$ . Тогда для любого  $K > 0$  закон управления (13), и фильтр (4) обеспечивают выполнение целевого условия (3).

**Доказательство.** Поскольку фильтр (4) является высокочастотным, то можно считать, что  $\lambda\sigma$  представляет собой достаточно малое число. Перепишем (14) при  $\mu = 0$  и  $\lambda\sigma = 0$  в виде:

$$\dot{\bar{\varepsilon}}(t) = \left( \frac{\partial \Phi(\bar{\varepsilon}, t)}{\partial \bar{\varepsilon}} \right)^{-1} (-kK\bar{\varepsilon}(t) + \varphi(t)). \quad (15)$$

Для анализа устойчивости (15) зададим функцию Ляпунова как  $V = 0,5\bar{\varepsilon}^2$ . Дифференцируя ее по времени, получим

$$\dot{V} = \left( \frac{\partial \Phi(\bar{\varepsilon}_\mu, t)}{\partial \bar{\varepsilon}_\mu} \right)^{-1} (-kK\bar{\varepsilon}^2 + \varphi\bar{\varepsilon}). \quad (16)$$

Рассмотрим следующие оценки выражения (16):

$$\begin{aligned} \dot{V} &= \left( \frac{\partial \Phi(\bar{\varepsilon}, t)}{\partial \bar{\varepsilon}} \right)^{-1} \left( -\frac{kK}{2}\bar{\varepsilon}^2 + \frac{1}{2kK}\varphi^2 - \left( \sqrt{\frac{kK}{2}}\bar{\varepsilon} - \sqrt{\frac{1}{2kK}}\varphi \right)^2 \right) \leq \\ &\leq \left( \frac{\partial \Phi(\bar{\varepsilon}, t)}{\partial \bar{\varepsilon}} \right)^{-1} \left( -\frac{kK}{2}\bar{\varepsilon}^2 + \frac{1}{2kK}\varphi^2 \right) \leq \\ &\leq -kK \left( \frac{\partial \Phi(\bar{\varepsilon}, t)}{\partial \bar{\varepsilon}} \right)^{-1} V + \frac{1}{2kK} \left( \frac{\partial \Phi(\bar{\varepsilon}, t)}{\partial \bar{\varepsilon}} \right)^{-1} \bar{\varphi}^2. \end{aligned} \quad (17)$$

Решим дифференциальное неравенство (17), используя принцип сравнения [13]:

$$V \leq \left( V(0) + \frac{\bar{\varphi}^2}{2k^2K^2} \right) e^{-kK \left( \frac{\partial \Phi(\bar{\varepsilon}, t)}{\partial \bar{\varepsilon}} \right)^{-1} t} + \frac{\bar{\varphi}^2}{2k^2K^2}. \quad (18)$$

Следовательно, решение уравнения (15) ограниченное. Перепишем (14) при  $0 < \mu < \mu_0$  и  $\lambda\sigma = 0$  в виде:

$$\begin{aligned} \dot{\varepsilon}_\mu(t) &= \left( \frac{\partial \Phi(\bar{\varepsilon}_\mu, t)}{\partial \bar{\varepsilon}_\mu} \right)^{-1} \times \\ &\times \left( -kK\varepsilon_\mu(t) - kK \frac{p - p(\mu p + 1)^{p-1} - b\mu}{p(\mu p + 1)^{p-1} + b\mu} \varepsilon_\mu(t) + \varphi(t) \right). \end{aligned} \quad (19)$$

Решение дифференциального уравнения (19) непрерывно зависит от параметра  $\mu$ . Согласно [14, 15, теорема 2.2] существует  $\mu_0$  такое, что при  $\mu < \mu_0$  и  $\lambda\sigma = 0$  выполнено условие  $|\bar{\varepsilon} - \varepsilon_\mu| < O(\mu)$ , где  $\lim_{\mu \rightarrow 0} O(\mu) = 0$ .

$O(\mu)$  описывает асимптотическое поведение функции  $\bar{\varepsilon} - \varepsilon_\mu$  при  $\mu \rightarrow 0$ . Если  $\mu$  достаточно близко к нулю, то  $|\bar{\varepsilon} - \varepsilon_\mu|$  меньше некоторой константы, умноженной на  $\mu$ . В результате решение уравнения (19) ограничено.

Аналогично получаем, что при  $\mu < \mu_0$  и  $\lambda\sigma < \sigma_0$  выполнено условие  $|\varepsilon_\mu - \varepsilon| < O(\lambda\sigma)$ , где  $\lim_{\lambda\sigma \rightarrow 0} O(\lambda\sigma) = 0$ .

В результате решение уравнения (14) ограничено. Из теоремы 1 следует, что ограничение (7) буд-

дет выполнено. Поскольку выполнены условия  $|\hat{y}(t) - y(t)| \leq a \leq \min\left(\frac{\bar{g}(t) - g(t)}{2}\right)$ , то можно обеспечить выполнение (3). Теорема 2 доказана.

**Замечание 2.** С учетом условий  $|\varepsilon_\mu - \varepsilon| < O(\lambda\sigma)$  и  $|\bar{\varepsilon} - \varepsilon_\mu| < O(\mu)$ , из неравенства (18) следует, что при  $t \rightarrow \infty$  имеем  $|\varepsilon| < \frac{\bar{\varphi}}{\sqrt{kK}} + O(\mu) + O(\lambda\sigma)$ . Значит, можно

уменьшить значение  $|\varepsilon|$  в установившемся режиме за счет увеличения  $K$  и уменьшения  $\mu$  и  $\lambda\sigma$ . Если значения  $K$ ,  $\lambda\sigma$  и  $\mu$  остаются неизменными, то в установившемся режиме значение  $|\varepsilon|$  зависит от  $\bar{\varphi}$ . Согласно закону управления (13), увеличение  $\varphi$  приведет к увеличению  $u(t)$  в установившемся режиме.

**Замечание 3.** Пусть  $\varepsilon' = \Phi(z, t)$ . Тогда  $\varphi(t)$ ,  $\dot{\varepsilon}$  и  $u(t)$  можно переписать в следующей форме

$$\begin{aligned} \varphi'(t) &= -\frac{p\Delta Q(p)}{Q_m(p)}y(t) + \frac{p}{Q_m(p)}f(y, t) + \dot{w}(t) + \\ &+ \dot{\varepsilon}'(t) - \frac{\partial \Phi'(\varepsilon', t)}{\partial t}, \end{aligned} \quad (20)$$

$$\begin{aligned} \dot{\varepsilon}'(t) &= \left( \frac{\partial \Phi(\varepsilon', t)}{\partial \varepsilon'} \right)^{-1} \times \\ &\times \left( -kK\varepsilon'(t) - kK \frac{p - p(\mu p + 1)^{p-1} - b\mu}{p(\mu p + 1)^{p-1} + b\mu} \varepsilon'(t) + \varphi'(t) \right). \end{aligned} \quad (21)$$

$$u'(t) = -\frac{Q_m(p)}{R_m(p)[p(\mu p + 1)^{p-1} + b\mu]}K\varepsilon'(z(t), t). \quad (22)$$

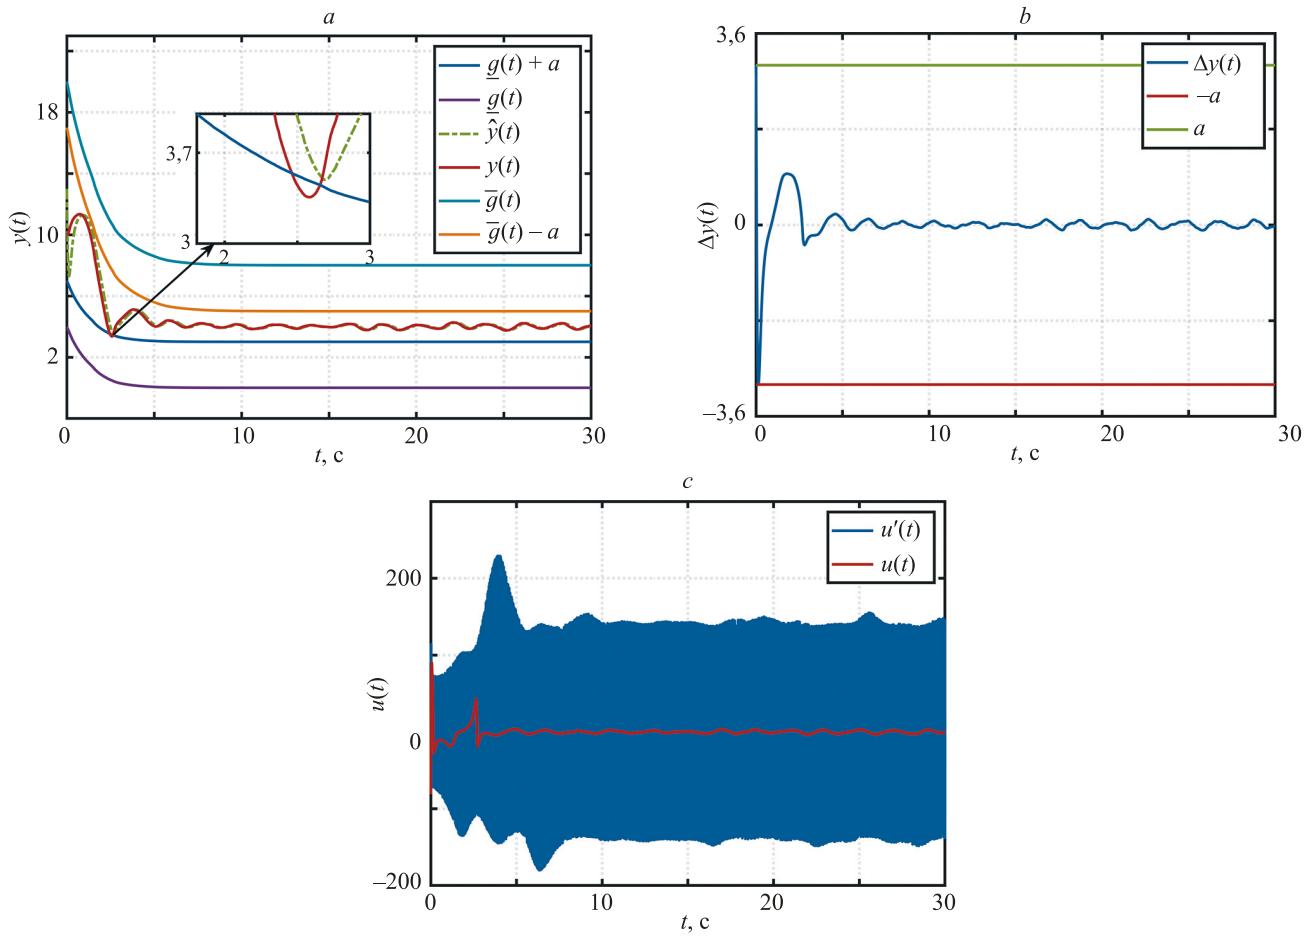
Из (20) следует, что  $\varphi'$  зависит от  $\dot{w}$ . Поскольку  $w$  является высокочастотным шумом, то его производная значительно увеличивает значение  $\bar{\varphi}'$ . Анализ устойчивости по переменной  $\varepsilon'$  аналогичен, как в доказательстве теоремы 2. При  $t \rightarrow \infty$ ,  $|\varepsilon'| < \frac{\bar{\varphi}}{\sqrt{kK}} + O(\mu)$ .

Увеличение  $\bar{\varphi}'$  приводит к увеличению  $\varepsilon'$ , что, в свою очередь — к увеличению  $u'$  в установившемся режиме. Значит, наличие шума  $w$  способствует увеличению неопределенности системы. Для поддержания системы в устойчивом состоянии контроллеру требуется расходовать больше энергии. Увеличение  $\bar{\varphi}'$  также является причиной, что  $z$  будет ближе к границе, что увеличивает вычислительную нагрузку и иногда может привести к значительным ошибкам в моделировании. Введение фильтра преобразует  $\dot{w}$  в  $\varphi$  к форме  $\frac{\lambda\sigma}{(\lambda\sigma p + 1)}\dot{w}$ , что эквивалентно применению низкочастотного фильтра к  $\dot{w}$ , уменьшая таким образом значение  $\bar{\varphi}$ . Введение ФНЧ не меняет структуру закона управления. Отметим, что если  $\lim_{\lambda\sigma \rightarrow 0} O(\lambda\sigma) = 0$ , то значение  $O(\lambda\sigma)$  можно считать пренебрежимо малым по сравнению с  $\dot{w}$ . В результате, в установившемся режиме значение  $u$  должно быть значительно меньше, чем  $u'$ .

### Численное моделирование

Рассмотрим объект управления вида

$$(p^2 + q_0 p)y(t) = u(t) + f(y, t),$$

Рисунок. Переходные процессы по:  $\hat{y}(t)$  и  $y(t)$  (а);  $\Delta y(t)$  (б);  $u(t)$  и  $u'(t)$  (в)Figure. Transient processes by:  $\hat{y}(t)$  and  $y(t)$  (a);  $\Delta y(t)$  (b);  $u(t)$  and  $u'(t)$  (c)

$$z(t) = y(t) + w(t),$$

$$f(t) = 0,1 + \sin(3t) + \text{sat}\left(\frac{d(t)}{0,3}\right), \quad (23)$$

где  $\text{sat}\{\cdot\}$  — функция насыщения;  $d(t)$  — белый шум, который смоделирован в MATLAB/Simulink с помощью блока Band-Limited White Noise,  $f = 2,1$ . Возможные значения параметра в (23) заданы неравенством:  $-1 \leq q_0 \leq 1$ ,  $w(t) = \sin(0,5 \cdot 10^3 t) + \sin(10^3 t) + \sin(10^4 t)$ ,  $y(0) = 10$ .

Выберем  $\varepsilon = \ln \frac{g + a - \hat{y}}{\hat{y} - \bar{g} + a}$ ,  $a = 3$ ,  $\underline{g} = (4 - 0,01)e^{-t} + 0,01$ ,  $\bar{g} = (20 - 8,01)e^{-0,7t} + 8,01$ ,  $K = 2$ ,  $Q_m(p) = (p + 1)^2$ ,  $R_m(p) = 1$ ,  $p = 2$ ,  $b = 0,1$ ,  $\mu = 0,01$ ,  $\lambda\sigma = 0,07$ ,  $y(0) = 13$ . Тогда закон управления (13), преобразование координат (8) и фильтр (4) запишем как

$$u = -\frac{2(p+1)(p+1)\varepsilon}{p(0,01p+1)+0,001},$$

$$\varepsilon = \ln \frac{(4 - 0,01)e^{-t} + 0,01 - \hat{y}}{\hat{y} - (20 - 8,01)e^{-0,7t} - 8,01},$$

$$\hat{y}(t) = \frac{1}{(0,07p+1)^2}z(t) + \frac{13}{(0,07p+1)}.$$

Для демонстрации преимуществ предложенного в настоящей работе решения, рассмотрим алгоритм [8] с теми же параметрами. Закон управления (22) и преобразование координат (21) будут иметь вид

$$u' = -\frac{2(p+1)(p+1)}{p(0,01p+1)+0,001}\varepsilon',$$

$$\varepsilon' = \ln \frac{(4 - 0,01)e^{-t} + 0,01 - z}{z - (20 - 8,01)e^{-0,7t} - 8,01}.$$

На рисунке, а, б видно, что максимальное значение  $\Delta y$  равно 3, и закон управления (13) обеспечил  $\hat{y}(t) \in \hat{\mathcal{Y}}$ . Условие  $|\Delta y| \leq a < \min\left(\frac{\bar{g}(t) - \underline{g}(t)}{2}\right)$  выполнено, когда  $y(t) \in \mathcal{Y}$  при любом времени  $t \geq 0$ . Из рисунка, в, видно, что с помощью фильтра (4) не только исключены некоторые высокочастотные компоненты из  $u'$ , но и уменьшено значение  $u$  в установившемся режиме.

### Заключение

В работе предложен новый алгоритм управления нелинейными объектами, гарантирующий определение регулируемой переменной в заданном множестве. Результат поиска осуществлен в условиях параметриче-

ских неопределенностей, внешних возмущений и высокочастотных шумов в измерениях на основе линейного фильтра низких частот и нелинейного преобразования координат. Выполнен анализ преимуществ применения представленного метода управления в условиях помех в измерениях. Разработанный алгоритм заметно

снижает влияние высокочастотного шума на регулируемый сигнал и энергопотребление системы управления. Результаты моделирования показали эффективность предложенного алгоритма и подтвердили теоретические выводы.

## Литература

- Boizot N., Busvelle E., Gauthier J.P. An adaptive high-gain observer for nonlinear systems // *Automatica*. 2010. V. 46. N 9. P. 1483–1488. <https://doi.org/10.1016/j.automatica.2010.06.004>
- Sanfelice R.G., Praly L. On the performance of high-gain observers with gain adaptation under measurement noise // *Automatica*. 2011. V. 47. N 10. P. 2165–2176. <https://doi.org/10.1016/j.automatica.2011.08.002>
- Prasov A.A., Khalil H.K. A nonlinear high-gain observer for systems with measurement noise in a feedback control framework // *IEEE Transactions on Automatic Control*. 2013. V. 58. N 3. P. 569–580. <https://doi.org/10.1109/TAC.2012.2218063>
- Vasiljevic L.K., Khalil H.K. Error bounds in differentiation of noisy signals by high-gain observers // *Systems & Control Letters*. 2008. V. 57. N 10. P. 856–862. <https://doi.org/10.1016/j.sysconle.2008.03.018>
- Wang L., Astolfi D., Su H., Marconi L., Isidori A. Output stabilization for a class of nonlinear systems via high-gain observer with limited gain power // *IFAC-PapersOnLine*. 2015. V. 48. N 11. P. 730–735. <https://doi.org/10.1016/j.ifacol.2015.09.276>
- Astolfi D., Marconi L. A high-gain nonlinear observer with limited gain power // *IEEE Transactions on Automatic Control*. 2015. V. 60. N 11. P. 3059–3064. <https://doi.org/10.1109/TAC.2015.2408554>
- Furtat I.B., Nekhoroshevikh A.N. Robust stabilization of linear plants under uncertainties and high-frequency measurement noises // Proc. of the 25<sup>th</sup> Mediterranean Conference on Control and Automation (MED). 2017. P. 1275–1280. <https://doi.org/10.1109/MED.2017.7984293>
- Furtat I.B., Gushchin P. Nonlinear feedback control providing plant output in given set // *International Journal of Control*. 2022. V. 95. N 6. P. 1533–1542. <https://doi.org/10.1080/00207179.2020.1861336>
- Furtat I.B., Gushchin P.A., Huy N.B. Nonlinear control providing the plant inputs and outputs in given sets // *European Journal of Control*. 2024. V. 76. P. 100944. <https://doi.org/10.1016/j.ejcon.2023.100944>
- Wen X., Furtat I.B. Nonlinear feedback control based on a coordinate transformation in multi-machine power systems // *Cybernetics and Physics*. 2023. V. 12. N 2. P. 157–161. <https://doi.org/10.35470/2226-4116-2023-12-2-157-161>
- Kundur P. *Power System Stability and Control*. New York: McGraw-Hill, 1994. P. 17.
- Wang Y., Guo G., Hill D.J. Robust decentralized nonlinear controller design for multimachine power systems // *Automatica*. 1997. V. 33. N 9. P. 1725–1733. [https://doi.org/10.1016/S0005-1098\(97\)00091-5](https://doi.org/10.1016/S0005-1098(97)00091-5)
- Khalil H.K. *Nonlinear Systems*. Upper Saddle River: Prentice Hall, 2002. P. 102.
- Bauer S.M., Filippov S.B., Smirnov A.L., Tovstik P.E., Vaillancourt R. *Asymptotic Methods in Mechanics of Solids*. Springer Nature, 2015. P. 89. <https://doi.org/10.1007/978-3-319-18311-4>
- Васильева А.Б., Бутузов В.Ф. Асимптотические разложения решений сингулярно возмущенных уравнений. М.: Наука, 1973. С. 27.

## Авторы

**Вэнь Сюэчэн** — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-8676-6696>, [xuecheng.wen@outlook.com](mailto:xuecheng.wen@outlook.com)

**Фуртат Игорь Борисович** — доктор технических наук, профессор, профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация; руководитель подразделения, главный научный сотрудник, Институт проблем машиноведения Российской академии наук, Санкт-Петербург, 199178, Российская Федерация, <https://orcid.org/0000-0003-4679-5884>, [cainenash@mail.ru](mailto:cainenash@mail.ru)

Статья поступила в редакцию 22.06.2024  
Одобрена после рецензирования 20.08.2024  
Принята к печати 25.09.2024

## References

- Boizot N., Busvelle E., Gauthier J.P. An adaptive high-gain observer for nonlinear systems. *Automatica*, 2010, vol. 46, no. 9, pp. 1483–1488. <https://doi.org/10.1016/j.automatica.2010.06.004>
- Sanfelice R.G., Praly L. On the performance of high-gain observers with gain adaptation under measurement noise. *Automatica*, 2011, vol. 47, no. 10, pp. 2165–2176. <https://doi.org/10.1016/j.automatica.2011.08.002>
- Prasov A.A., Khalil H.K. A nonlinear high-gain observer for systems with measurement noise in a feedback control framework. *IEEE Transactions on Automatic Control*, 2013, vol. 58, no. 3, pp. 569–580. <https://doi.org/10.1109/TAC.2012.2218063>
- Vasiljevic L.K., Khalil H.K. Error bounds in differentiation of noisy signals by high-gain observers. *Systems & Control Letters*, 2008, vol. 57, no. 10, pp. 856–862. <https://doi.org/10.1016/j.sysconle.2008.03.018>
- Wang L., Astolfi D., Su H., Marconi L., Isidori A. Output stabilization for a class of nonlinear systems via high-gain observer with limited gain power. *IFAC-PapersOnLine*, 2015, vol. 48, no. 11, pp. 730–735. <https://doi.org/10.1016/j.ifacol.2015.09.276>
- Astolfi D., Marconi L. A high-gain nonlinear observer with limited gain power. *IEEE Transactions on Automatic Control*, 2015, vol. 60, no. 11, pp. 3059–3064. <https://doi.org/10.1109/TAC.2015.2408554>
- Furtat I.B., Nekhoroshevikh A.N. Robust stabilization of linear plants under uncertainties and high-frequency measurement noises. *Proc. of the 25<sup>th</sup> Mediterranean Conference on Control and Automation (MED)*, 2017, pp. 1275–1280. <https://doi.org/10.1109/MED.2017.7984293>
- Furtat I.B., Gushchin P. Nonlinear feedback control providing plant output in given set. *International Journal of Control*, 2022, vol. 95, no. 6, pp. 1533–1542. <https://doi.org/10.1080/00207179.2020.1861336>
- Furtat I.B., Gushchin P.A., Huy N.B. Nonlinear control providing the plant inputs and outputs in given sets. *European Journal of Control*, 2024, vol. 76, pp. 100944. <https://doi.org/10.1016/j.ejcon.2023.100944>
- Wen X., Furtat I.B. Nonlinear feedback control based on a coordinate transformation in multi-machine power systems. *Cybernetics and Physics*, 2023, vol. 12, no. 2, pp. 157–161. <https://doi.org/10.35470/2226-4116-2023-12-2-157-161>
- Kundur P. *Power System Stability and Control*. New York, McGraw-Hill, 1994, pp. 17.
- Wang Y., Guo G., Hill D.J. Robust decentralized nonlinear controller design for multimachine power systems. *Automatica*, 1997, vol. 33, no. 9, pp. 1725–1733. [https://doi.org/10.1016/S0005-1098\(97\)00091-5](https://doi.org/10.1016/S0005-1098(97)00091-5)
- Khalil H.K. *Nonlinear Systems*. Upper Saddle River: Prentice Hall, 2002, pp. 102.
- Bauer S.M., Filippov S.B., Smirnov A.L., Tovstik P.E., Vaillancourt R. *Asymptotic Methods in Mechanics of Solids*. Springer Nature, 2015, pp. 89. <https://doi.org/10.1007/978-3-319-18311-4>
- Васильева А.Б., Бутузов В.Ф. Асимптотические разложения решений сингулярно возмущенных уравнений. С. 27.

## Authors

**Xuecheng Wen** — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-8676-6696>, [xuecheng.wen@outlook.com](mailto:xuecheng.wen@outlook.com)

**Igor B. Furtat** — D.Sc., Full Professor, ITMO University, Saint Petersburg, 197101, Russian Federation; Head of Department, Chief Researcher, Institute of Problems of Mechanical Engineering of the Russian Academy of Sciences, Saint Petersburg, 199178, Russian Federation, <https://orcid.org/0000-0003-4679-5884>, [cainenash@mail.ru](mailto:cainenash@mail.ru)

Received 22.06.2024  
Approved after reviewing 20.08.2024  
Accepted 25.09.2024

## НОВЫЕ МАТЕРИАЛЫ И НАНОТЕХНОЛОГИИ

## MATERIAL SCIENCE AND NANOTECHNOLOGIES

doi: 10.17586/2226-1494-2024-24-5-751-757

УДК 541.64:539.2

### Влияние качества растворителя на трибологические свойства полимерных щеток

Иван Васильевич Лукиев<sup>1</sup>✉, Иван Викторович Михайлов<sup>2</sup>, Олег Владимирович Борисов<sup>3</sup>

<sup>1,3</sup> Университет ИТМО, Санкт-Петербург, 197101, Российской Федерации

<sup>1,2,3</sup> Институт высокомолекулярных соединений Российской академии наук, Санкт-Петербург, 199004, Российской Федерации

<sup>1</sup> ivan.lukiev@mail.ru✉, <https://orcid.org/0000-0003-3022-0496>

<sup>2</sup> georg\_om@mail.ru, <https://orcid.org/0000-0001-5591-1002>

<sup>3</sup> oleg.borisov@univ-pau.fr, <https://orcid.org/0000-0002-9281-9093>

#### Аннотация

**Введение.** Полимерные щетки, как модифицирующие покрытия, значительно улучшают трибологические свойства различных контактирующих поверхностей. Трение, которое возникает при наложении внешней нагрузки и латеральном сдвиге полимерных щеток друг относительно друга, определяется их энергией взаимодействия и глубиной взаимопроникновения. Если щетки погружены в низкомолекулярный растворитель, силу трения можно регулировать, варьируя качество растворителя за счет изменения внешних условий: температуры, химического состава раствора и т. п. Отметим, что теоретические исследования, посвященные влиянию качества растворителя на трибологические свойства щеток, практически отсутствуют. **Метод.** Для определения влияния качества растворителя на взаимодействие плоских полимерных щеток использовались два взаимодополняющих подхода: аналитический и численный методы самосогласованного поля. В обоих случаях применялась крупнозернистая модель полимерных щеток. Качество растворителя в модели задавалось через параметр Флори–Хаггинса взаимодействия полимер–растворитель. **Основные результаты.** Проведена количественная оценка ширины зоны перекрывания, распирающего давления и силы трения, возникающей при сближении щеток друг с другом. Предложено теоретическое описание силы трения в режиме малых скоростей сдвига на основе уравнения Бринкмана для двух сжатых щеток, скользящих друг против друга. **Обсуждение.** Показано, что при постоянстве общей степени полимеризации, плотности прививки и скорости латерального сдвига щеток относительно друг друга ширина зоны перекрывания одинаково убывает с увеличением межплоскостного расстояния по степенному закону независимо от качества растворителя. В условиях сильного сжатия плоских полимерных щеток сила трения стремится к определенному предельному значению, в то время как коэффициент трения стремится к нулю в независимости от качества растворителя. В области умеренного давления коэффициент трения существенно возрастает с уменьшением растворимости привитых полимеров при одинаковых приложенной внешней нагрузке и составе плоских полимерных щеток. Аналитический метод показал высокую согласованность с данными проведенного численного моделирования. Полученные результаты позволяют прогнозировать трибологические свойства полимерных щеток в зависимости от качества растворителя и, как следствие, предсказывать влияние внешних условий на силу трения между модифицированными поверхностями.

#### Ключевые слова

полимерные щетки, сила трения, метод самосогласованного поля

#### Благодарности

Работа выполнена при поддержке Российского научного фонда, грант № 23-13-00174.

**Ссылка для цитирования:** Лукиев И.В., Михайлов И.В., Борисов О.В. Влияние качества растворителя на трибологические свойства полимерных щеток // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 751–757. doi: 10.17586/2226-1494-2024-24-5-751-757

## Impact of solvent quality on tribological properties of polymer brushes

Ivan V. Lukiev<sup>1</sup>, Ivan V. Mikhailov<sup>2</sup>, Oleg V. Borisov<sup>3</sup>

<sup>1,3</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>1,2,3</sup> Institute of Macromolecular Compounds RAS, Saint Petersburg, 199004, Russian Federation

<sup>1</sup> ivan.lukiev@mail.ru, <https://orcid.org/0000-0003-3022-0496>

<sup>2</sup> georg\_om@mail.ru, <https://orcid.org/0000-0001-5591-1002>

<sup>3</sup> oleg.borisov@univ-pau.fr, <https://orcid.org/0000-0002-9281-9093>

### Abstract

Polymer brushes, as modifying coatings, significantly improve the tribological properties of various contacting surfaces. The friction that arises when an external load is applied and the polymer brushes laterally shift relative to each other is determined by their interaction energy and the depth of interpenetration. If the brushes are immersed in a low-molecular-weight solvent, the friction force can be controlled by varying the solvent quality through changes in external conditions, such as temperature, chemical composition of the solution, and so on. It should be noted that theoretical studies on the effect of solvent quality on the tribological properties of brushes are practically absent. To determine the influence of solvent quality on the interaction of flat polymer brushes, two complementary approaches were used: analytical and numerical self-consistent field methods. In both cases, a coarse-grained model of polymer brushes was employed. The solvent quality in the model was defined through the Flory-Huggins parameter for polymer-solvent interaction. A quantitative assessment of the overlap zone width, osmotic pressure, and friction force arising when the brushes approach each other was conducted. A theoretical description of the friction force in the low shear rate regime was proposed based on the Brinkman equation for two compressed brushes sliding against each other. It was shown that, with constant total polymerization degree, grafting density, and lateral sliding speed of the brushes relative to each other, the width of the overlap zone decreases following a power law with increasing inter-plane distance, regardless of solvent quality. Under conditions of strong compression of flat polymer brushes, the friction force approaches a certain limiting value, while the friction coefficient tends to zero, independent of solvent quality. In the moderate pressure region, the friction coefficient significantly increases with a decrease in the solubility of the grafted polymers under the same applied external load and the composition of the flat polymer brushes. The analytical method showed high agreement with the data from the numerical simulations. The obtained results allow for predicting the tribological properties of polymer brushes depending on solvent quality and, consequently, predicting the effect of external conditions on the friction force between modified surfaces.

### Keywords

polymer brushes, friction force, self-consistent field method

### Acknowledgements

The work was supported by the Russian Science Foundation, grant No. 23-13-00174.

**For citation:** Lukiev I.V., Mikhailov I.V., Borisov O.V. Impact of solvent quality on tribological properties of polymer brushes. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 751–757 (in Russian). doi: 10.17586/2226-1494-2024-24-5-751-757

### Введение

Полимерные щетки — нанослои, состоящие из полимерных цепей, одним концом химически привитых к непроницаемой поверхности. Модификация контактирующих поверхностей полимерными щетками позволяет значительно улучшить их трибологические свойства, снижая трение между поверхностями на несколько порядков. Системы, состоящие из двух параллельных взаимодействующих полимерных щеток, привлекают к себе особое внимание [1]. Теоретические [2–4] и экспериментальные [5, 6] работы, а также исследования с помощью компьютерного моделирования [2, 7, 8], преимущественно сосредоточены на изучении взаимодействия полимерных щеток при их сжатии под внешней нагрузкой. Так, например, в работе [7] изучено влияние полидисперсности на взаимопроникновение в сжатых щетках. Установлено, что, в отличие от монодисперсных щеток, где ширина зоны взаимопроникновения увеличивается при сжатии, для умеренно полидисперсных щеток она практически не зависит от межплоскостного расстояния. В случае сильно полидисперсных щеток их взаимопроникновение снижается при уменьшении межплоскостного расстояния. В работе [8] показано, что с увеличением внешнего давле-

ния коэффициент трения между взаимодействующими плоскими полимерными щетками уменьшается в условиях атермического растворителя. Помимо давления, взаимодействие полимерных щеток, и, как следствие, возникающее между ними трение можно регулировать, изменения химическое строение прививаемых полимеров и качество растворителя, в который они погружены.

Цель настоящей работы — изучение влияния качества растворителя на взаимодействие плоских полимерных щеток, а именно: ширину зоны перекрывания, распирающее давление, силу трения и коэффициент трения. Для реализации этой цели использованы теоретические подходы, разработанные в рамках аналитической теории самосогласованного поля (ССП), и численное моделирование методом Схойтенса–Флира.

### Модель и метод

Рассмотрим полимерную систему, состоящую из линейных полимерных щеток, цепи которых погружены в низкомолекулярный растворитель. Каждая полимерная цепь состоит из  $N$  одинаковых мономерных единиц (в настоящей работе  $N = 500$ ); цепи прививаются к поверхности с плотностью прививки  $\sigma$  ( $\sigma = 0,1$ ), определяемой как количество привитых полимерных цепей

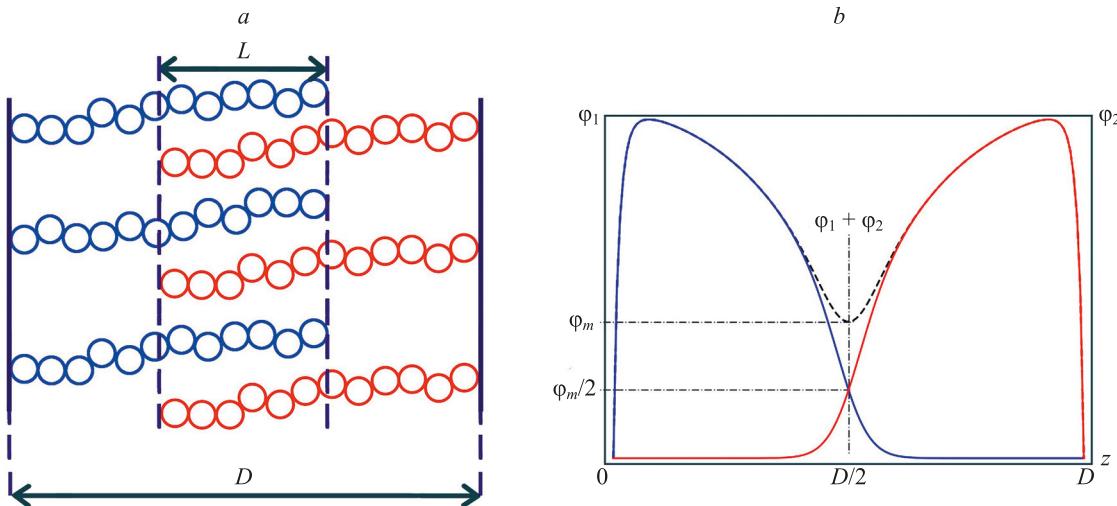


Рис. 1. Схематическое изображение моделируемой системы (а) и пример распределения объемной доли привитых полимеров (б).

$\phi_{1,2}$  — объемные доли первого и второго полимера соответственно,  $\phi_m$  — серединная плотность полимерной системы,  $z$  — расстояние от поверхности прививки

Fig. 1. Schematic representation of the modeling system (a) and the example of volume fraction distribution of grafted polymers (b) where  $\phi_{1,2}$  are the volume fractions of the first and second polymers, respectively,  $\phi_m$  is the mid-plane density of the polymer system, and  $z$  is the distance from grafting surface

на единицу площади поверхности. Цепи прививались к двум параллельным плоским поверхностям, расположенным на расстоянии  $D$  друг от друга (рис. 1).

Когда полимерные щетки сближаются на достаточное расстояние, привитые цепи противоположных щеток начинают перекрываться. Параметр  $L$  представляет собой ширину зоны перекрывания.

Для описания энергетической несовместимости молекул мономерных звеньев привитых цепей и молекул растворителя используется параметр Флори–Хаггинса  $\chi$ , значения которого менялись от 0 до 1 с шагом 0,25.

В качестве инструмента моделирования применен одноградиентный численный метод ССП Схойтенса–Флира. Применение данного метода для исследования полимерных щеток и его алгоритм подробно описаны в работах [9–11].

Метод ССП основан на использовании пространственной решетки, учитывает геометрию и симметрию рассматриваемой системы. В рамках метода блуждание полимерных цепей осуществляется на кубической решетке. В ходе итерационной процедуры происходит расчет статистической суммы по всем возможным конформациям привитых цепей и осуществляется минимизация свободной энергии системы. Размер ячейки решетки принят равным линейному размеру мономерного звена  $a$ . Каждая ячейка может быть занята мономерной единицей или молекулой растворителя. Ячейки решетки организованы в виде плоских слоев, параллельных к поверхности прививки. В пределах одного слоя на расстоянии  $z$  от поверхности прививки объемные доли мономерных звеньев и химический потенциал считаются однородными. В качестве единицы длины в работе использован размер мономерного звена  $a$ , в качестве единицы энергии —  $k_B T$ , где  $k_B$  — константа Больцмана,  $T$  — абсолютная температура.

Расчеты ССП выполнены с помощью программы sfbox, разработанной в лаборатории физической и коллоидной химии Вагенингенского университета (Нидерланды).

## Результаты и обсуждение

Коэффициент трения  $\mu$  в общем случае определим как отношение силы трения  $f$  между латерально скользящими друг относительно друга щетками к нормальному давлению  $\Pi$ , при котором поверхности прививки сближаются на расстояние

$$\mu(D) = \frac{f(D)}{\Pi(D)}. \quad (1)$$

Согласно теории Бринкмана [8] для протекаемой модели полимерных щеток, погруженных в низкомолекулярный растворитель, сила трения может быть рассчитана по формуле [8]:

$$f(D) = \eta V \int_0^D \frac{\phi_1^2(z)\phi_2^2(z)}{\phi_1^2(z) + \phi_2^2(z)} dz, \quad (2)$$

где  $\eta$  — коэффициент трения, приходящийся на один контакт между любыми двумя мономерными звеньями;  $V$  — скорость латерального сдвига поверхностей прививки.

Распределение объемной доли мономерных звеньев в зоне контакта полимерных щеток можно описать с помощью серединной плотности  $\phi_m = \phi_{1,2}(D/2)$  (рис. 1, б) [8]:

$$\phi_{1,2}(z) = \frac{\phi_m}{2} \left[ 1 \pm \tanh\left(\frac{\phi_m^2(z - D/2)}{2\Gamma}\right) \right], \quad (3)$$

где  $\Gamma$  — интеграл перекрывания. Подставляя уравнение (3) в уравнение (2), легко показать, что

$$f(D) = \frac{\pi - 2}{4} \eta \Gamma. \quad (4)$$

Интеграл перекрывания  $\Gamma$  определяется как

$$\Gamma = \int_0^D \phi_1(z) \phi_2(z) dz. \quad (5)$$

Уравнение (5) может быть записано через серединную плотность и ширину зоны перекрывания щеток:

$$\Gamma = k L \phi_m^2, \quad (6)$$

где  $k$  — некоторый коэффициент пропорциональности, который зависит от способа определения ширины зоны перекрывания. В настоящей работе в дальнейшем под  $L$  будем понимать удвоенный первый момент распределения объемной доли мономерных звеньев, проникающих в противоположную щетку за серединной плоскостью:

$$L(D) = 2 \frac{\int_D^{D/2} \phi_1(z) z dz}{\int_{D/2}^D \phi_1(z) dz}.$$

В работе [12] в рамках аналитической теории ССП было показано, что данная скейлинговая зависимость,

$$L(D) \simeq a^{4/3} N^{2/3} D^{-1/3}, \quad (7)$$

не чувствительна к качеству растворителя, что также подтверждается выполненным численным моделированием (рис. 2).

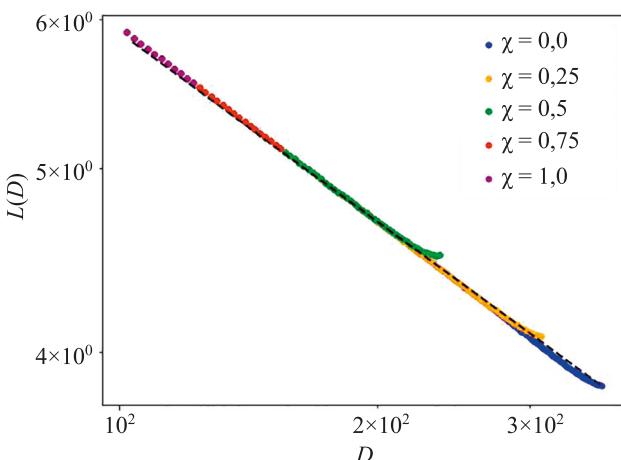


Рис. 2. Ширина зоны перекрывания взаимодействующих щеток, как функция межплоскостного расстояния ( $N = 500$ ,  $\sigma = 0,1$ ) в логарифмических координатах.

$\chi$  отображает энергетическую несовместимость молекул мономерных звеньев привитых цепей и молекул растворителя. Точками обозначены данные численного моделирования.

Пунктирная линия соответствует зависимости  $L(D) = 0,435N^{2/3}D^{-1/3}$

Fig. 2. Overlapping zone width of interacting brushes as a function of interplanar distance ( $N = 500$ ,  $\sigma = 0.1$ ) in logarithmic coordinates. Dots indicate numerical simulation data.  $\chi$  represents the energetic incompatibility between the monomeric units of grafted chains and the solvent molecules.

The dotted line corresponds to the dependence  $L(D) = 0,435N^{2/3}D^{-1/3}$

Чтобы определить серединную плотность в работе [7] предложен следующий теоретический прием. Предположим, что одна из щеток сжимается не аналогичной щеткой, а непроницаемой стенкой. Рассчитаем плотность возле этой стенки на расстоянии  $d = D/2$  от поверхности прививки:

$$\phi_m = \phi_0(d) + \frac{1}{d} \int_d^{H_0} \phi_0(z) dz, \quad (8)$$

где  $\phi_0(z)$  и  $H_0$  — профиль объемной доли и толщина несжатой щетки.

Профиль  $\phi_0(z)$  найдем на основе профиля химического потенциала  $U(z)$ . При условии «сильного», но при этом гауссового растяжения привитых цепей в [12] показано, что эффективный химический потенциал для полимерных щеток имеет параболическую форму:

$$U(z) = \frac{3\pi^2}{8N^2}(H_0^2 - z^2). \quad (9)$$

По определению химический потенциал — вариация профиля плотности осмотической части свободной энергии  $f_{init}$  по профилю объемной доли:

$$U(z) = \frac{\delta f_{init}[\phi_0(z)]}{\delta \phi_0(z)}. \quad (10)$$

Отметим, что осмотическая часть свободной энергии определяется через объемную долю полимера и параметр Флори–Хаггинса:

$$f_{init}(\phi) = (1 - \phi) \ln(1 - \phi) + \phi(1 - \phi)\chi - (\chi - 1)\phi. \quad (11)$$

Совокупность уравнений (8)–(11) позволяет аналитически рассчитать серединную плотность как функцию межплоскостного расстояния. Данная зависимость также демонстрирует высокую согласованность с результатами прямого моделирования (рис. 3, a).

С учетом уравнений (6) и (7) серединная плотность также дает возможность рассчитать интеграл перекрытия по формуле:

$$\Gamma = 0,2N^{2/3}D^{-1/3}\phi_m^2. \quad (12)$$

Коэффициент 0,2 отвечает наилучшему соответствуанию между численным и аналитическим методами (рис. 3, b).

Рассчитаем аналитически зависимость распирающего давления от межплоскостного расстояния [8]:

$$\Pi(D) = \phi_m(D) \frac{\partial f_{init}[\phi_m(D)]}{\partial \phi_m(D)} - f_{init}[\phi_m(D)]. \quad (13)$$

В численном моделировании распирающее давление может быть напрямую рассчитано через производную свободной энергии на единицу площади прививки  $F(D)$ :

$$\Pi(D) = -\frac{\partial F(D)}{\partial D}. \quad (14)$$

Отметим, что значения распирающего давления, полученные аналитически (13) и на основе численного моделирования (14) согласуются (рис. 3, c).

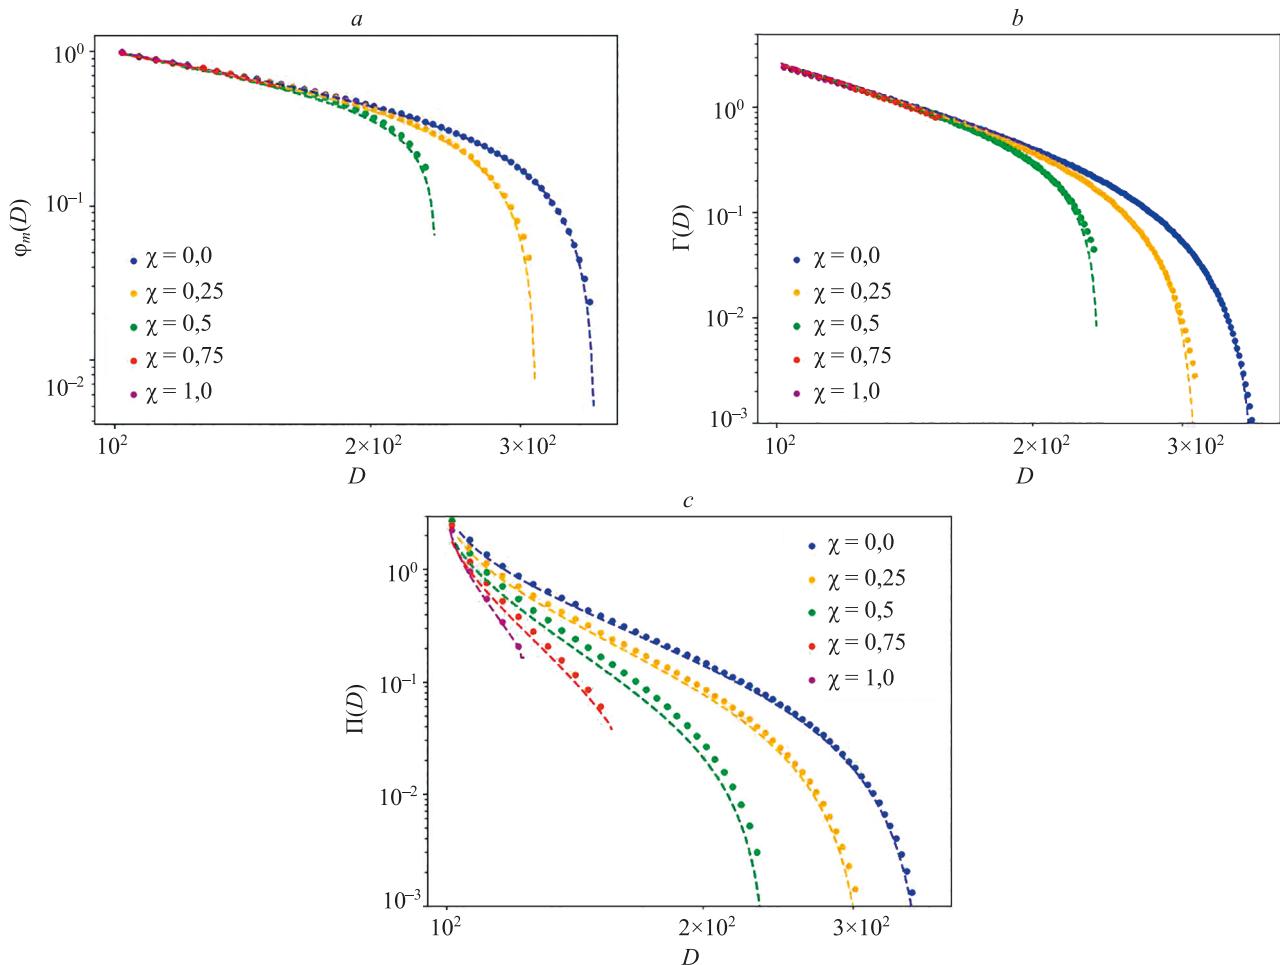


Рис. 3. Серединная плотность (*a*), интеграл перекрывания (*b*) и распирающее давление (*c*), как функции межплоскостного расстояния в логарифмических координатах. Точками обозначены данные численного моделирования, пунктиром — аналитические зависимости,  $N = 500$ ,  $\sigma = 0,1$

Fig. 3. Mid-plane density (*a*), overlap integral (*b*), and disjoining pressure (*c*) as a function of interplanar distance in logarithmic coordinates. Hereinafter, dots indicate numerical simulation data, dotted lines are analytical dependences,  $N = 500$ ,  $\sigma = 0.1$

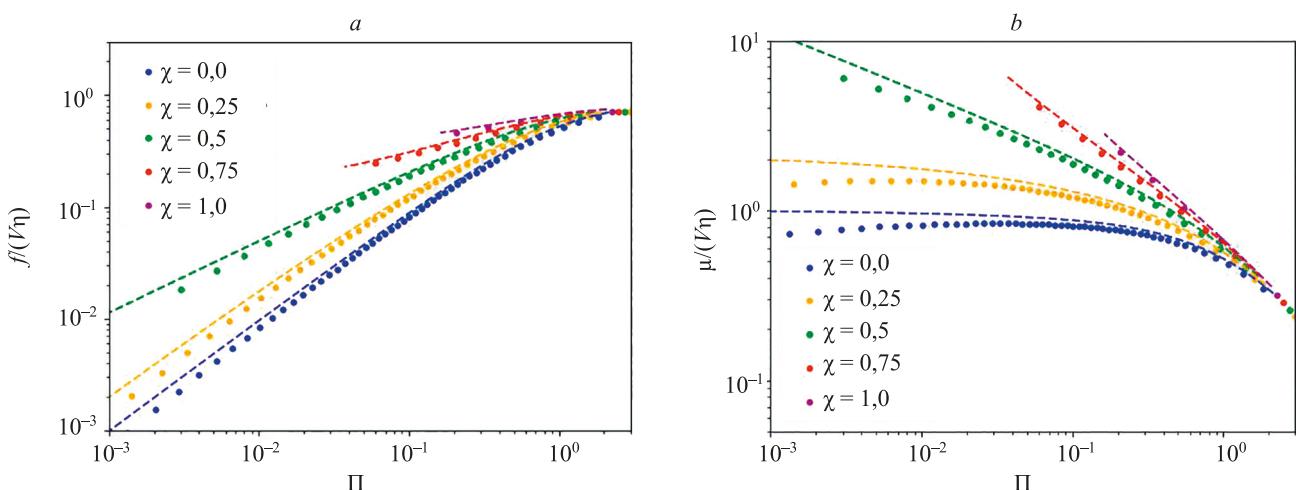


Рис. 4. Зависимости приведенной силы трения, приходящейся на единицу площади прививки, от приложенной нагрузки (равной нормальному распирающему давлению) в логарифмических координатах (*a*) и приведенного коэффициента трения от приложенного нормального сжимающего давления в логарифмических координатах (*b*)

Fig. 4. Dependences of the reduced friction force per unit area of the grafting surface on the applied load (equal to the normal expanding pressure) in logarithmic coordinates (*a*) and the friction coefficient vs. the applied normal compressive pressure of the brush in logarithmic coordinates (*b*)

Таким образом, замкнутая система уравнений (1), (4), (8)–(13) позволяет аналитически получить зависимости силы трения и коэффициента трения от приложенной нагрузки. Уравнения (2) и (14) описывают те же данные из численного моделирования (рис. 4).

Исходя из зависимостей (рис. 4), можно сделать вывод, что при сильном сжатии щеток сила трения стремится к некоторому предельному значению, а коэффициент трения к нулю вне зависимости от качества растворителя. В области умеренного сжатия щеток коэффициент трения увеличивается по мере изменения качества растворителя от атермического и далее к тета условиям и условиям плохого растворителя. Данные выводы справедливы при постоянной плотности прививки и степени полимеризации привитых цепей, а также при фиксированной скорости латерального сдвига щеток относительно друг друга.

Для аналитического расчета всех приведенных характеристик взаимодействующих щеток от комбинации параметров  $N$ ,  $\sigma$ ,  $\chi$  была написана библиотека на языке Python<sup>1</sup>.

<sup>1</sup> [Электронный ресурс]. Режим доступа: <https://github.com/IvanMikhailovIMCRAS/ascf.git> (дата обращения: 10.06.2024).

## Литература

1. Kreer T. Polymer-brush lubrication: a review of recent theoretical advances // *Soft Matter*. 2016. V. 12. N 15. P. 3479–3501. <https://doi.org/10.1039/C5SM02919H>
2. Wijmans C.M., Zhulina E.B., Fleer G.J. Effect of free polymer on the structure of a polymer brush and interaction between two polymer brushes // *Macromolecules*. 1994. V. 27. N 12. P. 3238–3248. <https://doi.org/10.1021/ma00090a017>
3. Milner S.T. Hydrodynamic penetration into parabolic brushes // *Macromolecules*. 1991. V. 24. N 12. P. 3704–3705. <https://doi.org/10.1021/ma00012a036>
4. Harden J.L., Cates M.E. Deformation of grafted polymer layers in strong shear flows // *Physical Review E*. 1996. V. 53. N 4. P. 3782–3787. <https://doi.org/10.1103/PhysRevE.53.3782>
5. Pelletier E., Stamouli A., Belder G.F., Hadzioannou G. Adsorption kinetics of an asymmetric diblock copolymer: A surface forces apparatus study // *Langmuir*. 1997. V. 13. N 7. P. 1884–1886. <https://doi.org/10.1021/la960884t>
6. Drobek T., Spencer N.D., Heuberger M. Compressing PEG brushes // *Macromolecules*. 2005. V. 38. N 12. P. 5254–5259. <https://doi.org/10.1021/ma0504217>
7. Klushin L.I., Skvortsov A.M., Qi S., Kreer T., Schmid F. Polydispersity effects on interpenetration in compressed brushes // *Macromolecules*. 2019. V. 52. N 4. P. 1810–1820. <https://doi.org/10.1021/acs.macromol.8b02361>
8. Klushin L.I., Ivanova A.S., Polotsky A.A., Skvortsov A.M. Interpenetration and friction of brush-coated surfaces under external load: analytical theory and SCF calculations // *Macromolecules*. 2023. V. 56. N 13. P. 5188–5200. <https://doi.org/10.1021/acs.macromol.3c00458>
9. Fleer G.J., Cohen-Stuart M.A., Scheutjens J.M.H.M., Cosgrove T., Vincent B. *Polymers at Interfaces*. Chapman & Hall, 1993. 502 p.
10. Wijmans C.M., Scheutjens J., Zhulina E.B. Self-consistent field theories for polymer brushes: lattice calculations and an asymptotic analytical description // *Macromolecules*. 1992. V. 25. N 10. P. 2657–2665. <https://doi.org/10.1021/ma00036a016>
11. de Vos W.M., Leermakers F.A.M. Modeling the structure of a polydisperse polymer brush // *Polymer*. 2009. V. 50. N 1. P. 305–316. <https://doi.org/10.1016/j.polymer.2008.10.025>
12. Zhulina E.B., Borisov O.V., Priamitsyn V.A. Theory of steric stabilization of colloid dispersions by grafted polymers // *Journal of*

## Заключение

С помощью метода самосогласованного поля рассмотрено взаимодействие полимерных щеток из линейных макромолекул в растворе при вариации качества растворителя (атермический, хороший, тета и плохой). В условиях постоянства плотности прививки, общей степени полимеризации и скорости относительного латерального сдвига щеток ширина зоны перекрывания одинаково зависит от межплоскостного расстояния  $D$  для всех случаев (убывает по степенному закону  $-1/3$  формула (7)). В области сильного давления сила трения стремится к некоторому предельному значению, а коэффициент трения к нулю вне зависимости от качества растворителя. В области умеренного давления коэффициент трения увеличивается по мере ухудшения качества растворителя (увеличения  $\chi$ ).

Полученные результаты позволяют прогнозировать трибологические свойства полимерных щеток в зависимости от качества растворителя и таким образом открывают возможности управления этими свойствами. Предполагается дальнейшее изучение влияния архитектуры привитых макромолекул на взаимодействие полимерных щеток описанным методом.

## References

1. Kreer T. Polymer-brush lubrication: a review of recent theoretical advances. *Soft Matter*, 2016, vol. 12, no. 15, pp. 3479–3501. <https://doi.org/10.1039/C5SM02919H>
2. Wijmans C.M., Zhulina E.B., Fleer G.J. Effect of free polymer on the structure of a polymer brush and interaction between two polymer brushes. *Macromolecules*, 1994, vol. 27, no. 12, pp. 3238–3248. <https://doi.org/10.1021/ma00090a017>
3. Milner S.T. Hydrodynamic penetration into parabolic brushes. *Macromolecules*, 1991, vol. 24, no. 12, pp. 3704–3705. <https://doi.org/10.1021/ma00012a036>
4. Harden J.L., Cates M.E. Deformation of grafted polymer layers in strong shear flows. *Physical Review E*, 1996, vol. 53, no. 4, pp. 3782–3787. <https://doi.org/10.1103/PhysRevE.53.3782>
5. Pelletier E., Stamouli A., Belder G.F., Hadzioannou G. Adsorption kinetics of an asymmetric diblock copolymer: A surface forces apparatus study. *Langmuir*, 1997, vol. 13, no. 7, pp. 1884–1886. <https://doi.org/10.1021/la960884t>
6. Drobek T., Spencer N.D., Heuberger M. Compressing PEG brushes. *Macromolecules*, 2005, vol. 38, no. 12, pp. 5254–5259. <https://doi.org/10.1021/ma0504217>
7. Klushin L.I., Skvortsov A.M., Qi S., Kreer T., Schmid F. Polydispersity effects on interpenetration in compressed brushes. *Macromolecules*, 2019, vol. 52, no. 4, pp. 1810–1820. <https://doi.org/10.1021/acs.macromol.8b02361>
8. Klushin L.I., Ivanova A.S., Polotsky A.A., Skvortsov A.M. Interpenetration and friction of brush-coated surfaces under external load: analytical theory and SCF calculations. *Macromolecules*, 2023, vol. 56, no. 13, pp. 5188–5200. <https://doi.org/10.1021/acs.macromol.3c00458>
9. Fleer G.J., Cohen-Stuart M.A., Scheutjens J.M.H.M., Cosgrove T., Vincent B. *Polymers at Interfaces*. Chapman & Hall, 1993. 502 p.
10. Wijmans C.M., Scheutjens J., Zhulina E.B. Self-consistent field theories for polymer brushes: lattice calculations and an asymptotic analytical description. *Macromolecules*, 1992, vol. 25, no. 10, pp. 2657–2665. <https://doi.org/10.1021/ma00036a016>
11. de Vos W.M., Leermakers F.A.M. Modeling the structure of a polydisperse polymer brush. *Polymer*, 2009, vol. 50, no. 1, pp. 305–316. <https://doi.org/10.1016/j.polymer.2008.10.025>
12. Zhulina E.B., Borisov O.V., Priamitsyn V.A. Theory of steric stabilization of colloid dispersions by grafted polymers. *Journal of*

Colloid and Interface Science. 1990, V. 137, N 2. P. 495–511. [https://doi.org/10.1016/0021-9797\(90\)90423-L](https://doi.org/10.1016/0021-9797(90)90423-L)

*Colloid and Interface Science*, 1990, vol. 137, no. 2, pp. 495–511.  
[https://doi.org/10.1016/0021-9797\(90\)90423-L](https://doi.org/10.1016/0021-9797(90)90423-L)

### Авторы

**Лукиев Иван Васильевич** — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация; инженер, Институт высокомолекулярных соединений Российской академии наук, Санкт-Петербург, 199004, Российская Федерация, [sc](#) 57386570500, <https://orcid.org/0000-0003-3022-0496>, ivan.lukiev@mail.ru

**Михайлов Иван Викторович** — кандидат физико-математических наук, старший научный сотрудник, Институт высокомолекулярных соединений Российской академии наук, Санкт-Петербург, 199004, Российская Федерация, [sc](#) 56288088800, <https://orcid.org/0000-0001-5591-1002>, georg\_om@mail.ru

**Борисов Олег Владимирович** — доктор физико-математических наук, профессор, заведующий лабораторией, ведущий научный сотрудник, Институт высокомолекулярных соединений Российской академии наук, Санкт-Петербург, 199004, Российская Федерация; профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc](#) 7005214753, <https://orcid.org/0000-0002-9281-9093>, oleg.borisov@univ-pau.fr

### Authors

**Ivan V. Lukiev** — PhD Student, ITMO University, 197101, Russian Federation; Engineer, Institute of Macromolecular Compounds RAS, Saint Petersburg, 199004, Russian Federation, [sc](#) 57386570500, <https://orcid.org/0000-0003-3022-0496>, ivan.lukiev@mail.ru

**Ivan V. Mikhailov** — PhD (Physics & Mathematics), Senior Researcher, Institute of Macromolecular Compounds RAS, Saint Petersburg, 199004, Russian Federation, [sc](#) 56288088800, <https://orcid.org/0000-0001-5591-1002>, georg\_om@mail.ru

**Oleg V. Borisov** — D.Sc. (Physics & Mathematics), Professor, Head of Laboratory, Leading Researcher, Institute of Macromolecular Compounds RAS, Saint Petersburg, 199004, Russian Federation; Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc](#) 7005214753, <https://orcid.org/0000-0002-9281-9093>, oleg.borisov@univ-pau.fr

Статья поступила в редакцию 19.06.2024  
Одобрена после рецензирования 12.07.2024  
Принята к печати 21.09.2024

Received 19.06.2024  
Approved after reviewing 12.07.2024  
Accepted 21.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

## КОМПЬЮТЕРНЫЕ СИСТЕМЫ И ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ COMPUTER SCIENCE

doi: 10.17586/2226-1494-2024-24-5-758-769

УДК 004.93

### Совместное распознавание акустических сцен и аудиособытий с помощью многозадачного обучения компактных моделей

Максим Константинович Сурков<sup>✉</sup>

Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

[surkovmax007@mail.ru](mailto:surkovmax007@mail.ru)<sup>✉</sup>, <https://orcid.org/0000-0002-3929-7484>

#### Аннотация

**Введение.** Задача распознавания метаинформации заключается в выявлении и извлечении данных различной природы (речь, шумы, акустическая сцена, акустические события, аномальные звуки) из входного аудиосигнала. Существуют подходы, способные обеспечить высокую точность распознавания метаинформации различной природы в аудиозаписях. Данные модели часто опираются на глубокие нейронные сети с числом обучаемых параметров более сотни миллионов. Как следствие, такие модели невозможно использовать в реальных коммерческих системах, так как они ограничены в вычислительных ресурсах. Это влияет на работу умных устройств, таких как мобильные телефоны, умные часы, колонки, системы «умный дом». Обычно к умным устройствам предъявляются серьезные требования по энергоэффективности, что влияет на применение тех или иных компонентов в составе таких продуктов. Тактовые частоты процессоров, объемы оперативной и дисковой памяти в таких устройствах сильно ограничены и не способны работать с нейросетевыми моделями с большим числом обучаемых параметров. Подобные ограничения требуют поиска возможных решений, которые бы позволили применять технологии распознавания метаинформации в коммерческих устройствах. Возможным решением могут стать так называемые компактные нейросетевые модели, которые за счет архитектуры и многозадачных алгоритмов обучения способны распознавать метаинформацию в аудиозаписях и используют ограниченное число обучаемых параметров. Коммерческий интерес к данной задаче согласуется и с заинтересованностью научного сообщества. Так, в рамках международного конкурса под названием «Detection and Classification of Acoustic Scenes and Events» организаторами были сформулированы специальные подзадачи — распознавание акустической сцены при использовании низкоресурсных систем («Low-Complexity Acoustic Scene Classification») и детекции аудиособытий («Sound Event Detection with Weak Labels and Synthetic Soundscapes»). Важными исследовательскими вопросами являются как создание оптимальной архитектуры компактной нейронной сети, так и алгоритмов их обучения для получения низкоресурсной высокоточной системы распознавания акустических сцен и аудиособытий.

**Метод.** Исследование выполнено на основе корпуса данных задач Challenge «Low-Complexity Acoustic Scene Classification» и «Sound Event Detection with Weak Labels and Synthetic Soundscapes».

Предложена архитектура многозадачной нейронной сети, состоящая из общего кодировщика и двух независимых декодировщиков для каждой из двух задач.

Рассмотрены классические алгоритмы многозадачного обучения SoftMTL и HardMTL, а также разработаны их модификации CrossMTL, которые опираются на идею переиспользования данных от одной задачи при обучении

декодировщика решать вторую задачу, и FreezeMTL, в процессе которого обученные веса общего кодировщика замораживаются после обучения на первой задаче и используются для оптимизации второго декодировщика.

**Основные результаты.** Показано, что применение модификации CrossMTL дает возможность существенно

увеличить точность классификации акустических сцен и детекции аудиособытий по сравнению с классическими подходами SoftMTL и HardMTL. Алгоритм FreezeMTL позволяет получить модель, демонстрирующую точность классификации сцен в 42,44 % и детекции событий в 45,86 %, что сравнимо с показателями базовых решений задач 2023 года.

**Обсуждение.** Предложена компактная нейронная сеть, состоящая из 633,5 тыс. обучаемых параметров, требующая 43,2 млн арифметических операций для обработки аудио длиной в одну секунду.

Модель использует на 7,8 % меньше обучаемых параметров и на 40 % меньше арифметических операций по сравнению с наивным применением двух независимых моделей. Разработанную модель можно применить в

умных устройствах за счет уменьшения числа обучаемых параметров и арифметических операций, необходимых для ее применения.

© Сурков М.К., 2024

#### Ключевые слова

распознавание акустической сцены, детекция аудиособытий, компактные модели, многозадачные нейронные сети, многозадачное обучение, распознавание метаинформации, умные устройства, нейронные сети

**Ссылка для цитирования:** Сурков М.К. Совместное распознавание акустических сцен и аудиособытий с помощью многозадачного обучения компактных моделей // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 758–769. doi: 10.17586/2226-1494-2024-24-5-758-769

## Low-complexity multi task learning for joint acoustic scenes classification and sound events detection

Maxim K. Surkov✉

ITMO University, Saint Petersburg, 197101, Russian Federation

surkovmax007@mail.ru✉, <https://orcid.org/0000-0002-3929-7484>

#### Abstract

The task of automatic metainformation recognition from audio sources is to detect and extract data of various natures (speech, noises, acoustic scenes, acoustic events, anomalies) from a given audio input signal. This area is well developed and known to the scientific community and has various approaches with high quality. But, the vast majority of such methods are based on large neural networks with a huge number of weights to be trained. Subsequently, it is impractical to use them in environments with severely limited computing resources. The smart device industry is currently growing rapidly: smartphones, smart watches, voice assistants, TV, smart home. Such products have limitations in both processor and memory. At that moment, the State-of-the-Art way to cope with these conditions is to use so-called low-complexity models. Moreover, in recent years, the interest of the scientific community in the above-mentioned problem has been growing (DCASE Workshop). One of the most crucial subtasks in the global meta information recognition problem is the task of Automatic Scene Classification and the task of Sound Event Detection. The most important scientific questions are the development of both the optimal low-complexity neural network architecture and learning algorithms to obtain a low-resource, high-quality system for classifying acoustic scenes and detecting sound events. In this paper the datasets from DCASE Challenge “Low-Complexity Acoustic Scene Classification” and “Sound Event Detection with Weak Labels and Synthetic Soundscapes” were used. A multitask neural network architecture was proposed consisting of a common encoder and two independent decoders for each of the two tasks. The classical algorithms of multitask learning SoftMTL and HardMTL were considered, and their modifications were developed: CrossMTL, which is based on the idea of reusing data from one task when training the decoder to solve the second task, and FreezeMTL, in which the trained weights of the common encoder are frozen after training on the first task and used to optimize the second decoder. As a result of the experiments, it was shown that the use of the CrossMTL modification can significantly increase the accuracy of the classification of acoustic scenes and event detection in compare with classical approaches SoftMTL and HardMTL. The FreezeMTL algorithm made it possible to obtain a model that provides 42.44 % accuracy in scene classification and 45.86 % accuracy in event detection, which is comparable to the results of the baseline solutions of 2023. In this paper, a low-complexity neural network consisting of 633.5 K trainable parameters was proposed, requiring 43.2 M MACs to process one second audio. This approach uses 7.8 % fewer trainable parameters and 40 % fewer MACs compared to the naive application of two independent models. The developed model can be used in smart devices due to a small number of trainable parameters, as well as a small number of MACs required for its application.

#### Keywords

acoustic scene classification, sound event detection, compact models, multitask neural networks, multitask learning, meta-information recognition, smart devices, neural networks

**For citation:** Surkov M.K. Low-complexity multi task learning for joint acoustic scenes classification and sound events detection. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 758–769 (in Russian). doi: 10.17586/2226-1494-2024-24-5-758-769

## Введение

На сегодняшний день задача распознавания метаинформации в аудиосигнале является актуальной и вызывает большой интерес со стороны научного сообщества и коммерческих компаний. Она заключается в выявлении и извлечении информации различной природы (речь, шумы, акустическая сцена, акустические события, аномальные звуки) из поступающего входного аудиосигнала. На данный момент существуют подходы, способные обеспечить высокую точность распознавания метаинформации различной природы в аудиозаписях [1–6]. В работе [3] представлена модель Conformer, которая объединяет в себе две ключевые идеи в области глубоких нейронных сетей: сверточные

слои и механизм внимания. Рассмотрено несколько конфигураций полученной архитектуры с 10, 30 и 118 млн обучаемых параметров. Ученые смогли разработать модель, способную распознавать человеческую речь с наилучшей точностью, по сравнению с другими моделями при использовании тестового корпуса данных Librispeech [7]. В [6] описано несколько ключевых идей, с помощью которых была разработана модель Whisper-AT. Было замечено, что большая нейросетевая модель Whisper [5], состоящая из более 70 млн параметров, обладает свойством инвариантности распознавания речи относительно фонового музыкального шума, а также показано, как можно применить данную модель для задачи одновременного распознавания речи и выявления акустических событий и получить при этом

высокую точность распознавания итоговой системы. Одной из важнейших работ в области распознавания метаинформации является статья под названием All-in-One Transformer [8], где исследователи обратили внимание научного сообщества на универсальность слуховой системы человека. В [8] показано, что современные модели могут обладать тем же свойством, а именно в случае обучения системы решать сразу несколько задач распознавания информации в звуке одновременно, качество на каждой из задач будет выше по сравнению с результатами моделей, которые были обучены решать одну конкретную задачу. Их подход основан на использовании общего кодировщика для задач распознавания речи и акустических событий. Также был предложен способ многозадачного обучения модели, что в итоге привело к увеличению точности всей системы. В работе [9] в качестве базовой модели использован подход на основе коннекционистской временной классификации. В [10] была представлена модель BEATs, которая смогла превзойти лучшие решения в задаче распознавания акустических событий на крупнейшем корпусе данных Audioset [11]. Исследователи предложили обучать нейросетевую модель на основе Visual Transformer [12] вместе с аудиотокенизатором в режиме самообучения с последующим дообучением на задаче распознавания метаинформации. Полученная система, состоящая из более 90 млн параметров, способна распознавать аудиособытия из более 500 классов.

Помимо стандартных задач распознавания метаинформации из звука, существует ряд альтернативных содержательных задач: автоматическая аннотация аудио [13], распознавание эмоций в человеческой речи [14], ответы на вопросы по аудиосигналу [15], анализ музыкальных нот [16] и другие задачи распознавания и анализа метаинформации в аудиосигнале. Для каждой из перечисленных задач существует свое специализированное решение. Отметим, что в 2023 г. группой ученых из Alibaba Group был предложен подход Qwen-Audio [17], позволяющий решить все вышеупомянутые задачи при помощи одной общей модели, которая состоит из кодировщика Whisper-Large-V2 [5] из 640 млн обучаемых параметров и декодировщика QwenLM [18] из 7 млрд обучаемых параметров. В [17] предложен способ многозадачного обучения, который позволил получить систему, обеспечивающую более высокую точность по сравнению с лучшими аналогами, специализированными под каждую конкретную задачу.

Заметим, что каждый из описанных способов основан на использовании моделей, которые содержат десятки или даже сотни миллионов обучаемых параметров. Подобные модели неприменимы в активно развивающейся индустрии умных устройств (телефоны, часы, колонки), так как интеллектуальные устройства ограничены в вычислительных ресурсах, объеме оперативной и дисковой памяти. Данная проблема не оставила без внимания и научное сообщество, которое начало свое активное изучение данной задачи на ежегодной конференции Detection and Classification of Acoustic Scenes and Events (DCASE) Workshop, в рамках которой несколько лет назад целенаправленно были поставлены задачи распознавания акустической сцены

ASC («Low-Complexity Acoustic Scene Classification») и аудиособытий SED («Sound Event Detection with Weak Labels and Synthetic Soundscapes») при наличии ограничений на число обучаемых параметров и число операций умножения и сложения.

Первая задача заключается в том, чтобы по входной аудиозаписи длиной в одну секунду определить, в какой из 10 акустических сцен была сделана запись: в аэропорту, торговом центре, на станции метро, во время прогулки, на городской площади, на оживленной улице, в трамвае, автобусе, вагоне метро или в парке. В задаче существует два ограничения: размер модели не должен превышать 128 Кбайт, число операций сложения и умножения (MACs) — 30 млн. На данный момент самую высокую точность классификации показывает модель CP-Mobile [19]. Конфигурация модели, состоящая из 61 148 обучаемых параметров в 16-битном формате и требующая 29 419 156 операций, демонстрирует точность в 57 % по метрике accuracy, в то время как базовая модель 2023 г., представляющая собой многослойную сверточную нейронную сеть, достигала 42,9 %. Нейросеть CP-Mobile является 6-слойной сверточной нейронной сетью. Каждый слой внутри сети использует так называемые переходные, стандартные и пространственно-понижающие блоки (рис. 1), которые были разработаны специально для решения задачи классификации акустических сцен Acoustic Scene Classification (ASC).

Вторая задача заключается в том, чтобы во входной аудиозаписи длиной 10 с и по заранее зафиксированному списку аудиособытий определить, в каких частях аудио произошло каждое из событий. Отметим, что возникают ситуации, когда несколько событий происходят одновременно. Также существуют случаи, когда одно и то же событие повторяется несколько раз в разных частях записи, например лай собаки. Кроме того, во входной аудиозаписи каких-то событий может и не быть (рис. 2). Авторы задачи зафиксировали следующий список аудиособытий: звонок будильника, звуки блендера, мяуканье кошки, звук тарелок, лай собаки, звук электрической зубной щетки, звук жарки еды, звук смесителя, человеческая речь, звук пылесоса. Как и в первой задаче, в данной постановке есть несколько ограничений. В качестве обучающих данных представлено четыре набора данных с разметкой разной гранулярности: полностью размеченный корпус данных из 3,5 тыс. примеров, где для каждого аудиособытия известно, когда оно произошло; слабо размеченный корпус данных из 1,5 тыс. примеров, где для каждого аудиособытия известно лишь то, присутствует оно на записи или нет; 14 тыс. аудиозаписей без разметки, а также корпус данных из 10 тыс. синтетических примеров, сгенерированных с помощью инструмента Scaper [20].

Кроме ограниченного набора размеченных данных, учтено число операций сложения и умножения, необходимых для использования моделей. На данный момент большинство подходов опирается на архитектуру Convolutional Recurrent Neural Network (CRNN). Данная нейронная сеть состоит из нескольких слоев, каждый из которых представляет специально определенный

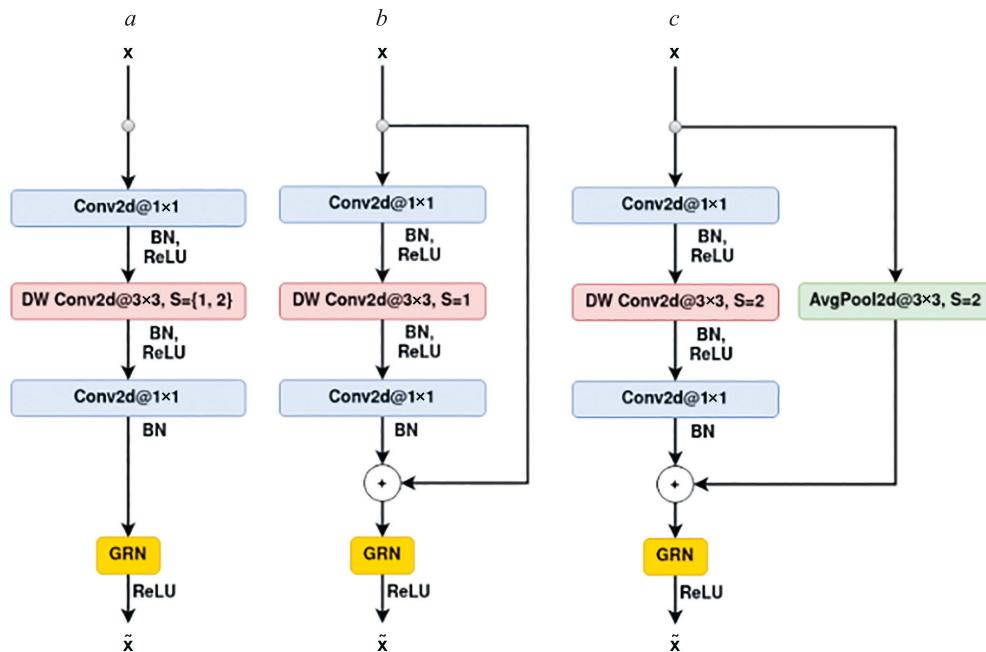


Рис. 1. Блоки одного слоя модели CP-Mobile [19] для классификации акустических сцен: переходный (*a*); стандартный (*b*); пространственно-понижающий (*c*).

BN — батч нормализация; DW — свертка по глубине; GRN — глобальная ответная нормализация; ReLU — выпрямленный линейный блок;  $x$  — входной сигнал;  $\tilde{x}$  — выходной сигнал

Fig. 1. Block types of one of the CP-Mobile [19] layers for acoustic scene classification problem: Transition Block (*a*); Standard Block (*b*); Spatial Downsampling Block (*c*).

BN — Batch Normalization; DW — Depthwise convolution; GRN — Global Response Normalization; ReLU — Rectified Linear Unit;  $x$  — input signal;  $\tilde{x}$  — output signal

блок сверток. По окончании применения всех сверток в сети, используется рекуррентная нейронная сеть, которая совершают предсказания для каждого момента времени каждого аудиособытия. Большое количество решений отличаются друг от друга построением сверточных блоков, а также особенностями обучения

моделей. Самым популярным алгоритмом, активно использующимся для решения задачи распознавания аудиособытий (Sound Event Detection, SED) с использованием данных с разметкой разной гранулярности, является так называемый mean-teacher [21]. В процессе обучения модели помимо основной обучаемой нейросети вычисляется так называемый учитель в виде экспоненциально взвешенного среднего за последние несколько шагов обучения. Итоговая функция потерь определяется как сумма бинарной кросс-энтропии и среднеквадратичной ошибки между предсказаниями обычной сети и ее экспоненциального среднего. Такой алгоритм позволяет эффективно использовать слаборазмеченные и неразмеченные данные. Авторский подход 2023 года основан на использовании 7-слойной сверточной нейронной сети в комбинации с двунаправленной рекуррентной нейросетью. Модель состоит из 1 млн параметров, требует 93 млн операций для обработки 1 с аудио и демонстрирует точность в 43,3 % по метрике Event-Based F1-score.

Таким образом, существует две важнейшие задачи в области распознавания метаинформации в звуке: ASC и SED. Для каждой из них существует ряд высокоточных решений, но такие модели требуют большого количества ресурсов или были разработаны специально для решения одной конкретной задачи: CP-Mobile (для решения задачи ASC), CRNN (для задачи SED). Вероятно, отсутствие универсальных подходов для одновременного решения вышеописанных задач при использовании ограниченного числа обучаемых пара-

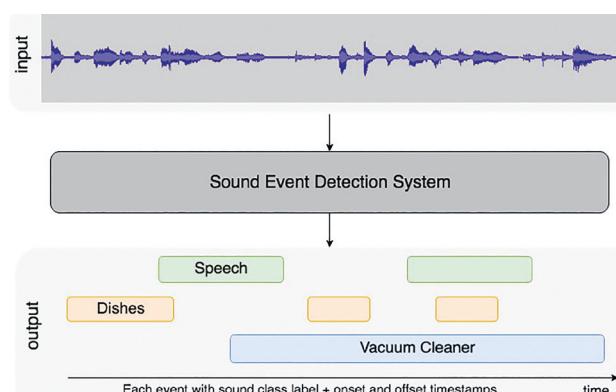


Рис. 2. Описание задачи распознавания аудиособытий.

input — входной аудиосигнал; output — предсказания модели; Sound Event Detection System — система детекции аудиособытий; Speech — речь; Dishes — звуки посуды; Vacuum Cleaner — звуки пылесоса; time — ось времени, «Each event with sound class label + onset and offset timestamps» — каждое событие с меткой соответствующего класса + время начала и конца события

Fig. 2. Definition of the Sound Event Detection problem

Таблица 1. Различия между задачами классификации акустических сцен (ASC) и распознавания аудиособытий (SED)

Table 1. Differences between Acoustic Scene Classification (ASC) and Sound Event Detection (SED) problems

Характеристики задачи	Задачи распознавания	
	ASC	SED
Длительность аудиозаписи, с	1	10
Максимальное число обучаемых параметров	$128 \cdot 10^3$	$1 \cdot 10^6$
Размер размеченного тренировочного корпуса данных, ч	38,8	9,6
Алгоритм обучения	supervised	self supervised (mean-teacher)
Число примеров в батче	256	48

метров и арифметических операций связано с рядом существенных различий в конфигурациях поставленных задач и в оптимальных гиперпараметрах моделей, сильно влияющих на точность предсказаний обученных нейросетей (табл. 1).

В машинном обучении применяется метод обучения нейронных сетей — «многозадачное обучение» (Multi Task Learning, MTL), который представляет собой алгоритм обучения одной нейронной сети, при котором модель учится решать несколько задач одновременно. Одно из первых своих успешных применений MTL нашел в компьютерном зрении, где исследователи предлагали различные архитектуры [22–28] для одновременного решения задач компьютерного зрения: классификации, семантической сегментации, детекции объектов. В задаче распознавания метаинформации из аудиосигнала многозадачное обучение было успешно использовано для увеличения точности предсказаний для одной задачи за счет добавления в исходную нейронную сеть ответвлений для вспомогательных задач [29, 30], а также для решения большого числа задач распознавания метаинформации за счет использования больших языковых моделей совместно с тщательной организацией обучения модели [17].

Таким образом, целью исследователей было одновременное решение как можно большего числа задач с использованием моделей, состоящих из сотен миллионов обучаемых параметров, или улучшение одной конкретной задачи при помощи вспомогательных. Однако не было найдено подходов, которые бы позволяли получить компактную модель, которая может решать одновременно задачи ASC и SED с точностью, близкой к моделям, решающим каждую из задач отдельно. В настоящей работе предложена компактная архитектура многозадачной нейронной сети с общим кодировщиком в виде многослойной сверточной нейронной сети с добавлением двух ответвлений для обеих задач. Для ее обучения применены несколько классических алгоритмов многозадачного обучения, предложен ряд модификаций данных алгоритмов, произведено сравнение методов между собой и с результатами обучения специализированных моделей для каждой из задач распознавания. Предложенная модель требует на 7,8 % меньше обучаемых параметров и на 40 % меньше арифметических операций по сравнению с наивным использованием двух независимых специализированных моделей. Модель способна одновременно решать задачу ASC с точностью 42,43 % по метрике accurasay

и задачу SED с точностью 45,89 % по метрике Event-Based F1-score, что сравнимо с точностью работы базовых подходов, предложенных авторами задач в 2023 г.

### Архитектура компактной многозадачной нейронной сети

Ключевую роль в алгоритме многозадачного обучения играет архитектура нейронной сети. Необходимо подобрать такую модель, которая бы подходила для решения задач ASC и SED. Дополнительно основной целью модели является экономия ресурсов будущей системы, поэтому необходимо, чтобы архитектура сети содержала меньшее число обучаемых параметров и требовала меньшее число арифметических операций по сравнению с двумя независимыми моделями, решающими каждую из задач отдельно.

Очевидной идеей для построения архитектуры многозадачной нейронной сети является адаптация модели, предназначеннной для решения одной из задач, для ее использования при решении второй задачи. В настоящей работе предлагается адаптировать модель CP-Mobile [19] для решения задачи SED. Для этого добавим в сеть еще два блока сверток (CPM BLOCK), а также рекуррентную нейронную сеть (RNN) аналогично структуре большинства высокоточных детекторов событий (рис. 3).

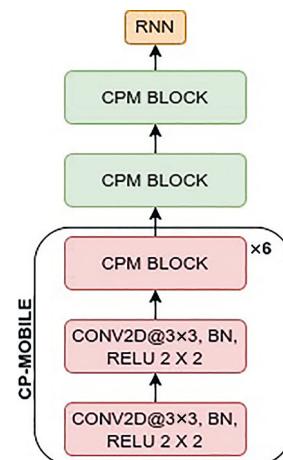


Рис. 3. Архитектура модели CP-Mobile-RNN, где CPM Block — специализированный блок модели CP-Mobile

Fig. 3. CP-Mobile-RNN model architecture, where CPM Block is a specialized unit of the CP-Mobile model

Далее обучим всю систему с помощью алгоритма mean-teacher [21] распознавать аудиособытия. Эксперименты показали, что предложенная модель обеспечивает точность SED в 35,54 %, что на 7,76 % меньше по сравнению с базовым подходом. С другой стороны, адаптация лучших детекторов событий для ASC невозможна из-за того, что они состоят из большого числа обучаемых параметров и требуют большего числа арифметических операций. Однако можно заметить, что, как и высокоточные классификаторы акустических сцен, так и лучшие детекторы аудиособытий имеют схожую структуру. Сначала для входной аудиозаписи строится мел-спектрограмма, после чего к ней применяется несколько сверточных слоев, в результате получается набор эмбеддингов для каждого момента времени. Затем классификатор акустической сцены применяет механизм внимания по оси времени в комбинации с линейным слоем, а детектор событий применяет к полученным эмбеддингам рекуррентную нейронную сеть (рис. 4). Таким образом, в обоих сценариях одинаковым образом строятся эмбеддинги, содержащие полезную информацию из аудио. Однако специализированные модели состоят из специально разработанных слоев с модифицированными свертками, предназначенными для решения конкретных задач. Вероятно, слои модели для решения одной задачи не подходят для решения другой задачи. Потому гипотетически разумным путем является использование обычных сверточных слоев для решения обеих задач. Эксперимент показал, что классическая сверточная нейросеть способна решать задачу ASC с точностью 53,31 %, а задачу SED с точностью 46,64 %, что на 11,1 % больше по сравнению с CP-Mobile-RNN. Видно, что данный подход менее точный по сравнению с самыми точными решениями задачи ASC в виде моделей

ли CP-Mobile, но он лучше адаптируется под задачу SED по сравнению с моделью CP-Mobile-RNN. Таким образом, итоговая структура многозадачной модели (MT model или Multi Task model) представляет из себя общий кодировщик, который по входному аудио строит последовательность эмбеддингов, которые затем обрабатываются декодировщиками для каждой из двух задач — механизмом внимания для задачи ASC, рекуррентной нейронной сетью для задачи SED (рис. 4). Стоит отметить, что ключевой особенностью данной модели является то, что в ней используются одни и те же эмбеддинги для двух задач. Другими словами, нет необходимости два раза строить две последовательности эмбеддингов для их последующей обработки, что приводит к существенному сокращению числа арифметических операций при использовании нейросети. В этом можно убедиться, вычислив размеры моделей, а также число арифметических операций, необходимых для их использования (табл. 2).

### Алгоритмы обучения многозадачной нейронной сети

Классический подход обучения многозадачных моделей — алгоритм SoftMTL — состоит из нескольких шагов. Нейронная сеть принимает на вход данные от двух задач и применяет к ним общий кодировщик, который вычисляет эмбеддинги для каждого момента времени. После этого полученные вектора обрабатываются декодировщиками для соответствующих задач. Далее вычисляются функции потерь ( $L_{total}$ ) для каждой задачи и складываются с некоторыми, заранее определенными коэффициентами (рис. 5). Данный алгоритм прост в реализации и позволяет обучать модель решать несколько задач одновременно, однако существуют пары задач,

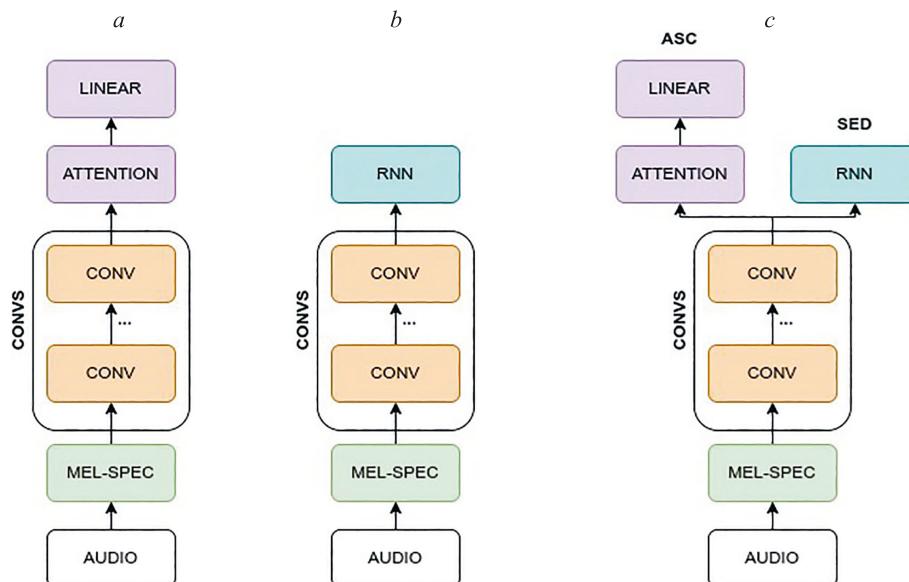


Рис. 4. Модели архитектуры: классификатора акустических сцен (ASC) (a); детектора аудиособытий (SED) (b); многозадачной модели (MTL) (c).

LINEAR — линейный слой; ATTENTION — механизм внимания; CONVS — сверточные слои; MEL-SPEC — мел-спектрограмма

Fig. 4. Model architectures of: acoustic scene classifier (a); sound event detector (b); multi task model (c)

Таблица 2. Число обучаемых параметров и арифметических операций, необходимых для использования моделей, где Baseline-2023 — базовое решение 2023 года

Table 2. The number of trainable model weights and multiply-accumulate operations needed for inference

Модель	Задача	Число обучаемых параметров	MACs для обработки аудио длительностью 1 с
Baseline-2023 ASC	ASC	<b><math>65 \cdot 10^3</math></b>	<b><math>29 \cdot 10^6</math></b>
CP-Mobile	ASC	$61 \cdot 10^3$	$29 \cdot 10^3$
Baseline-2023 SED	SED	<b><math>1 \cdot 10^6</math></b>	<b><math>93 \cdot 10^6</math></b>
CP-Mobile-RNN	SED	$966 \cdot 10^3$	$34 \cdot 10^3$
CNN	ASC	$60 \cdot 10^3$	$29 \cdot 10^3$
CRNN	SED	$628 \cdot 10^3$	$43 \cdot 10^3$
<b>MT</b>	<b>ASC+SED</b>	<b><math>634 \cdot 10^3</math></b>	<b><math>43 \cdot 10^3</math></b>

которые гипотетически могут быть не похожими друг на друга, как следствие при обучении нейронной сети линейная комбинация градиентов может приводить к

сходимости модели в локальные минимумы, в которых нейросеть будет показывать низкую точность на обеих задачах.

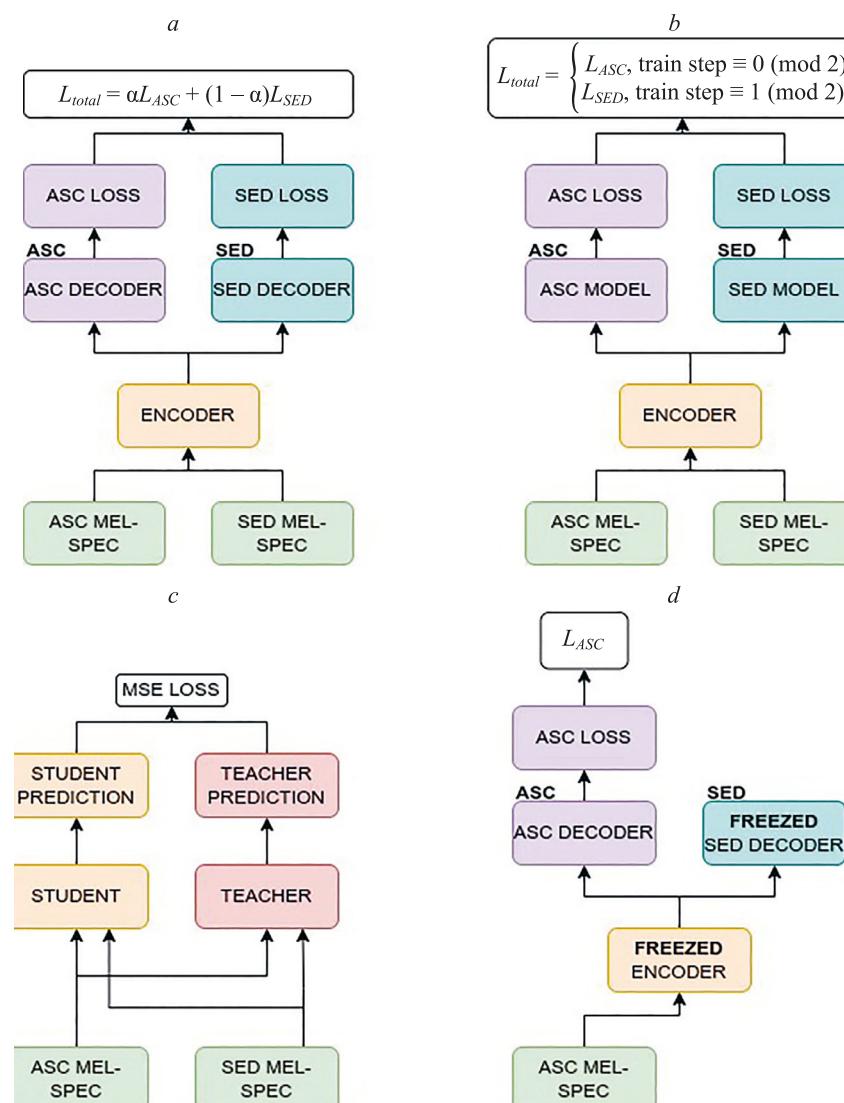


Рис. 5. Алгоритмы обучения многозадачных нейронных сетей: SoftMTL (a); HardMTL (b); CrossMTL (c); FreezeMTL (d), где  $\alpha$  — коэффициент при функции ошибки для задачи ASC, LOSS — функция ошибки, DECODER — декодировщик, MODEL — модель, ENCODER — кодировщик, STUDENT PREDICTION — предсказание модели-студента, TEACHER PREDICTION — предсказание модели-учителя

Fig. 5. Training algorithms for multi task neural networks: SoftMTL (a); HardMTL (b); CrossMTL (c); FreezeMTL (d)

Альтернативный способ обучения — алгоритм HardMTL, когда модель поочередно учится на данных первой и второй задач. Иными словами, модель обновляет веса подсети, отвечающей за решение первой задачи на четных шагах, а веса подсети, отвечающей за решение второй подзадачи — на нечетных шагах обучения (рис. 5).

Изучение алгоритма mean-teacher [21] для обучения модели SED на данных с разметкой разной гранулярности приводит к применению похожего подхода для многозадачного обучения. Назовем обучаемую многозадачную модель студентом. Предлагается, аналогично алгоритму mean-teacher, вычислять экспоненциальное взвешенное среднее модели-студента. Назовем это среднее — моделью-учителем. Заметим, что в классических алгоритмах SoftMTL и HardMTL данные от одной задачи никак не используются при вычислении градиентов и функции ошибки для подсети, решающей вторую задачу, так как для них нет соответствующей разметки. Однако можно применить так называемую дистилляцию знаний из модели-учителя в модель-студента. Предлагается использовать подсеть модели-учителя, решающую первую задачу к данным от второй задачи. Аналогичным образом применяется подсеть модели-студента и вычисляется среднеквадратичная ошибка между предсказаниями моделей студента и учителя. Наконец, данное среднеквадратичное отклонение суммируется со стандартной функцией потерь, которая вычисляется в алгоритмах SoftMTL и HardMTL (рис. 5). Гипотетически описанный подход CrossMTL должен увеличить точность обученных многозадачных моделей за счет использования большего количества данных.

Большой интерес представляет крайний случай алгоритма HardMTL, а именно, когда модель сначала учится решать одну задачу, а затем вторую задачу. Другими словами, вместо поочередного использования батчей данных от двух задач сначала обрабатывается большое число батчей от первой задачи, затем от второй. Однако такой подход в вышеописанном виде нежизнеспособен из-за так называемого явления под названием «Catastrophic Forgetting» [31–33]. Для того чтобы избежать данную проблему, предлагается использовать метод заморозки весов обучаемой модели — применять замороженные параметры в качестве констант. Сначала обучим нейросеть решать одну задачу, затем заморозим веса общего кодировщика, а также декодировщика для данной задачи. После чего дообучим декодировщик второй задачи. Разработанный алгоритм назовем FreezeMTL. Заметим, что при таком подходе декодировщик второй задачи будет использовать эмбеддинги, полученные с помощью кодировщика от первой задачи (рис. 5). В результате возникает несколько вопросов для изучения: каким образом эмбеддинги кодировщика первой задачи влияют на точность предсказаний декодировщика второй задачи, а также какую из двух рассматриваемых задач выбрать для обучения общего кодировщика. Задачи ASC и SED существенно отличаются друг от друга. В результате возможна ситуация, когда эмбеддинги, полученные с помощью кодировщика от первой задачи, могут содержать недостаточно полезной информации для решения

второй задачи и точность предсказаний на второй задаче может снизиться. На основании определения задач можно предположить, что SED является более сложной задачей по сравнению с ASC. Тогда эмбеддинги кодировщика для решения данной задачи должны содержать больше полезной информации, поэтому применение описанных эмбеддингов должно привести к получению более точной модели как с точки зрения классификации сцен, так и с точки зрения SED.

### Экспериментальное определение наиболее эффективного алгоритма обучения многозадачной модели распознавания метаинформации в звуке

В настоящей работе эксперименты проводились с использованием данных, предоставленных авторами задач DCASE Task 1 и DCASE Task 4. Для задачи ASC использован корпус данных, состоящий из 38,8 ч тренировочных и 8,2 ч валидационных аудиособытий с равномерным распределением акустических сцен в них. Для задачи SED применен датасет, состоящий из 9,6 ч полностью размеченных, 4,4 ч слабо-размеченных, 40 ч неразмеченных, 27,8 ч синтетических и 3,3 ч валидационных данных. Для каждого аудио была построена мел-спектрограмма со стандартными гиперпараметрами: частота дискретизации составляет 16 кГц, длина скользящего окна равна 128 мс, длина шага окна — 10 мс, число мел-фильтрбанков — 128. Во всех экспериментах использованы стандартные аугментации, маскирующие мел-спектрограммы, обнуляя 15 % значений по каждой из осей времени и мел-фильтрбанков.

Для обучения моделей применен оптимизатор AdamW со стандартными гиперпараметрами: скорость обучения — 0,001, бета-коэффициенты для вычисления бегущих средних градиентов равны 0,9 и 0,999. В качестве планировщика скорости обучения выбран стандартный планировщик с линейным увеличением скорости от 0 до 0,001 за первые 10 % шагов обучения с последующим уменьшением до нуля по косинусному закону.

В качестве первого подхода к обучению многозадачной нейросети взят алгоритм SoftMTL, в процессе которого функция потерь вычисляется как среднее значение между функциями потерями для каждой из задач. В результате обучения многозадачной сети с помощью данного алгоритма была получена модель, выдающая точности ASC в 37,59 % и SED — 39,08 % (табл. 3).

Из табл. 3 видно, что точность предсказания многозадачной модели ниже по сравнению с базовыми подходами. Гипотетически, это может быть связано с тем, что во время обучения две задачи конфликтуют между собой и линейная комбинация их градиентов может приводить к тому, что веса модели подбираются не оптимальным образом. Для того чтобы частично избавиться от подобного рода конфликтов градиентов, предлагается использовать алгоритм HardMTL, в процессе которого веса модели поочередно обновляются сначала для первой задачи, потом для второй. В результате применения данного алгоритма была получена модель,

Таблица 3. Результаты обучения моделей с использованием различных алгоритмов обучения многозадачной нейронной сети

Table 3. Experimental results of applying various training algorithms for training of multi task neural network

Алгоритм обучения	ASC accuracy, %	SED Event-based F1-score, %	Число обучаемых параметров	MACs
ASC baseline 2023	<b>42,90</b>	—	$65,0 \cdot 10^3$	$29,0 \cdot 10^6$
ASC SOTA (CP-Mobile [19])	57,00	—	$61,0 \cdot 10^3$	$29,0 \cdot 10^6$
SED baseline 2023	—	<b>43,30</b>	$1,0 \cdot 10^6$	$93,0 \cdot 10^6$
SED SOTA (FDY-LKA [34])	—	58,30	$9,0 \cdot 10^6$	$7,0 \cdot 10^9$
SoftMTL	37,59	39,08	$633,5 \cdot 10^3$	$43,2 \cdot 10^6$
HardMTL	40,92	39,05		
CrossSoftMTL	36,64	39,03		
CrossHardMTL	42,30	39,96		
<b>FreezeMTL (SED, ASC)</b>	<b>42,44</b>	<b>45,86</b>		
FreezeMTL (ASC, SED)	51,29	30,74		

имеющая точности ASC — 40,92 % и SED — 39,05 %. Видно, что данный подход детектирует события с такой же точностью, как и алгоритм SoftMTL, но существенно точнее классифицирует акустические сцены.

Заметим, что в алгоритмах SoftMTL и HardMTL данные одной задачи никак не используются при обучении декодировщика второй задачи. Гипотетически, большее количество обучающих данных должно привести к более высокоточной модели. Комбинация алгоритмов SoftMTL и CrossMTL под названием CrossSoftMTL позволяет получить модель, обладающей точностями ASC — 36,64 % и SED — 39,03 %, в то время как добавление CrossMTL в HardMTL приводит к обучению модели, которая демонстрирует точности ASC — 42,3 % и SED — 39,96 %. Видно, что алгоритм CrossMTL позволяет улучшить точность модели при его совместном применении с алгоритмом HardMTL, однако его комбинация с SoftMTL приводит к небольшому ухудшению точности ASC.

В заключение рассмотрим предельный случай алгоритма HardMTL, а именно ситуацию, когда модель сначала полностью учится только на данных первой задачи, затем веса общего кодировщика замораживаются, после чего декодировщик оставшейся задачи доучивается на данных своей задачи. Результаты применения данного алгоритма можно найти в табл. 3 в строках с алгоритмами FreezeMTL. Версия (SED, ASC) означает, что сначала модель была обучена решать задачу SED, а затем доучена решать задачу ASC. Исходя из результатов, указанных в табл. 3 можно сделать вывод о том, что точность решения задачи, которую модель была обучена решать первой, существенно выше по сравнению с точностью предсказаний для второй задачи. Это связано с тем, что фактически при обучении модели решать вторую задачу используются эмбеддинги, полученные с помощью кодировщика, который учился решать первую задачу. Заметим, что порядок, в котором модель учится решать задачу существенен. Если сначала модель обучить классифицировать ASC, то точность SED уменьшается до 30,74 %, что ниже результатов всех вышеупомянутых алгоритмов, в то время как при первоначальном обучении модели решать задачу SED точность ASC составляет 42,44 %, что выше, чем у остальных

подходов при одновременной точности SED в 45,86 %. Это говорит о том, что эмбеддинги, полученные с помощью кодировщика модели SED содержат больше полезной информации об аудиособытиях по сравнению с векторами, генерированными моделью ASC.

В результате проведенных экспериментов показано положительное влияние алгоритма CrossMTL на точность предсказаний финальных моделей. Получена многозадачная модель, обученная с помощью алгоритма FreezeMTL (SED, ASC), которая классифицирует ASC с точностью 42,44 %, что всего на 0,46 % меньше по сравнению с базовым подходом, а также позволяет детектировать аудиособытия с точностью 45,86 %, что больше базового подхода на 2,56 %. Более того, полученная модель содержит на 7,8 % меньше обучаемых параметров, а также требует на 40 % меньше арифметических операций по сравнению с наивным использованием двух независимых моделей ASC и SED (табл. 2).

## Заключение

Задача распознавания метаинформации в звуке представляет большой интерес как с точки зрения науки, так и с точки зрения индустрии. На данный момент существует множество подходов, позволяющих решать большинство из них при использовании больших нейронных сетей, состоящих из сотен миллионов параметров. Такие высокие требования к ресурсам не позволяют использовать данные методы в умных устройствах. Описанная проблема активно изучается на ежегодной конференции DCASE Workshop, где было представлено множество задач распознавания метаинформации. Для исследования были выбраны две задачи: классификации акустических сцен и детекции аудиособытий. В настоящей работе предложена компактная нейронная сеть, состоящая из 633,5 тыс. обучаемых параметров, требующая 43,2 млн арифметических операций для обработки аудио длиной в 1 с. Данный подход использует на 7,8 % меньше обучаемых параметров и на 40 % меньше арифметических операций по сравнению с наивным применением двух независимых моделей. Рассмотрены классические алгоритмы многозадачного обучения SoftMTL и HardMTL и предложены их

модификации CrossSoftMTL и CrossHardMTL. Изучен предельный случай алгоритма HardMTL, когда модель сначала учится решать одну задачу, затем веса общего кодировщика замораживаются и, наконец, модель доучивается решать вторую задачу. Данный алгоритм по-

зволяет обучить многозадачную модель, одновременно классифицировать акустические события с точностью 42,44 % (меньше базового решения на 0,46 %) и детектировать аудиособытия с точностью 45,86 % (что больше базового решения на 2,56 %).

## Литература

1. Kriman S., Beliaev S., Ginsburg B., Huang J., Kuchaiev O., Lavrukhin V., Leary R., Li J., Zhang Y. Quartznet: Deep automatic speech recognition with 1D time-channel separable convolutions // Proc. of the ICASSP 2020 — 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2020. P. 6124–6128. <https://doi.org/10.1109/icassp40776.2020.9053889>
2. Lakhotia K., Kharitonov E., Hsu W.-N., Adi Y., Polyak A., Bolte B., Nguyen T.-A., Copet J., Baevski A., Mohamed A., Dupoux E. On generative spoken language modeling from raw audio // Transactions of the Association for Computational Linguistics. 2021. V. 9. P. 1336–1354.
3. Gulati A., Qin J., Chiu C.-C., Parmar N., Zhang Y., Yu J., Han W., Wang S., Zhang Z., Wu Y., Pang R. Conformer: Convolution-augmented transformer for speech recognition // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2020. P. 5036–5040. <https://doi.org/10.21437/interspeech.2020-3015>
4. Hsu W.N., Tsai B., Bolte Y.-H.H., Salakhutdinov R., Mohamed A. HuBERT: How much can a bad teacher benefit ASR pre-training? // Proc. of the ICASSP 2021 — 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2021. P. 6533–6537. <https://doi.org/10.1109/icassp39728.2021.9414460>
5. Radford A., Kim J.W., Xu T., Brockman G., McLeavey C., Sutskever I. Robust speech recognition via large-scale weak supervision // Proceedings of Machine Learning Research, PMLR. 2023. V. 202. P. 28492–28518.
6. Gong Y., Khurana S., Karlinsky L., Glass J. Whisper-at: Noise-robust automatic speech recognizers are also strong general audio event taggers // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2023. P. 2798–2802. <https://doi.org/10.21437/interspeech.2023-2193>
7. Panayotov V., Chen G., Povey D., Khudanpur S. Librispeech: an asr corpus based on public domain audio books // Proc. of the IEEE International Conference On Acoustics, Speech and Signal Processing (ICASSP). 2015. P. 5206–5210. <https://doi.org/10.1109/icassp.2015.7178964>
8. Moritz N., Wichern G., Hori T., Le Roux J. All-in-One transformer: Unifying speech recognition, audio tagging, and event detection // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2020. P. 3112–3116. <https://doi.org/10.21437/interspeech.2020-2757>
9. Karita S., Soplin N.E.Y., Watanabe S., Delcroix M., Ogawa A., Nakatani T. Improving transformer-based end-to-end speech recognition with connectionist temporal classification and language model integration // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2019. P. 1408–1412. <https://doi.org/10.21437/interspeech.2019-1938>
10. Chen S., Wu Y., Wang C., Liu S., Tompkins D., Chen Z., Che W., Yu X., Wei F. Beats: Audio pre-training with acoustic tokenizers // Proceedings of Machine Learning Research. 2023. V. 202. P. 4672–4712.
11. Gemmeke J.F., Ellis D.P.W., Freedman D., Jansen A., Lawrence W., Moore R.C., Plakal M., Ritter M. Audio set: An ontology and human-labeled dataset for audio events // Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2017. P. 776–780. <https://doi.org/10.1109/icassp.2017.7952261>
12. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. An image is worth 16x16 words: Transformers for image recognition at scale // Proc. of the ICLR 2021 — 9<sup>th</sup> International Conference on Learning Representations. 2021.
13. Drossos K., Lipping S., Virtanen T. Clotho: An audio captioning dataset // Proc. of the ICASSP 2020 — 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2020. P. 736–740. <https://doi.org/10.1109/icassp40776.2020.9052990>
14. Kriman S., Beliaev S., Ginsburg B., Huang J., Kuchaiev O., Lavrukhin V., Leary R., Li J., Zhang Y. Quartznet: Deep automatic speech recognition with 1D time-channel separable convolutions. *Proc. of the ICASSP 2020 — 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020, pp. 6124–6128. <https://doi.org/10.1109/icassp40776.2020.9053889>
15. Lakhotia K., Kharitonov E., Hsu W.-N., Adi Y., Polyak A., Bolte B., Nguyen T.-A., Copet J., Baevski A., Mohamed A., Dupoux E. On generative spoken language modeling from raw audio. *Transactions of the Association for Computational Linguistics*, 2021, vol. 9, pp. 1336–1354.
16. Gulati A., Qin J., Chiu C.-C., Parmar N., Zhang Y., Yu J., Han W., Wang S., Zhang Z., Wu Y., Pang R. Conformer: Convolution-augmented transformer for speech recognition. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2020, pp. 5036–5040. <https://doi.org/10.21437/interspeech.2020-3015>
17. Hsu W.N., Tsai B., Bolte Y.-H.H., Salakhutdinov R., Mohamed A. HuBERT: How much can a bad teacher benefit ASR pre-training?. *Proc. of the ICASSP 2021 — 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2021, pp. 6533–6537. <https://doi.org/10.1109/icassp39728.2021.9414460>
18. Radford A., Kim J.W., Xu T., Brockman G., McLeavey C., Sutskever I. Robust speech recognition via large-scale weak supervision. *Proceedings of Machine Learning Research*, 2023, vol. 202, pp. 28492–28518.
19. Gong Y., Khurana S., Karlinsky L., Glass J. Whisper-at: Noise-robust automatic speech recognizers are also strong general audio event taggers. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2023, pp. 2798–2802. <https://doi.org/10.21437/interspeech.2023-2193>
20. Panayotov V., Chen G., Povey D., Khudanpur S. Librispeech: an asr corpus based on public domain audio books. *Proc. of the IEEE International Conference On Acoustics, Speech and Signal Processing (ICASSP)*, 2015, pp. 5206–5210. <https://doi.org/10.1109/icassp.2015.7178964>
21. Moritz N., Wichern G., Hori T., Le Roux L. All-in-One transformer: Unifying speech recognition, audio tagging, and event detection. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2020, pp. 3112–3116. <https://doi.org/10.21437/interspeech.2020-2757>
22. Karita S., Soplin N.E.Y., Watanabe S., Delcroix M., Ogawa A., Nakatani T. Improving transformer-based end-to-end speech recognition with connectionist temporal classification and language model integration. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2019, pp. 1408–1412. <https://doi.org/10.21437/interspeech.2019-1938>
23. Chen S., Wu Y., Wang C., Liu S., Tompkins D., Chen Z., Che W., Yu X., Wei F. Beats: Audio pre-training with acoustic tokenizers. *Proceedings of Machine Learning Research*, 2023, vol. 202, pp. 4672–4712.
24. Gemmeke J.F., Ellis D.P.W., Freedman D., Jansen A., Lawrence W., Moore R.C., Plakal M., Ritter M. Audio set: An ontology and human-labeled dataset for audio events. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2017, pp. 776–780. <https://doi.org/10.1109/icassp.2017.7952261>
25. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. et al. An image is worth 16×16 words: Transformers for image recognition at scale. *Proc. of the ICLR 2021 — 9<sup>th</sup> International Conference on Learning Representations*, 2021.
26. Drossos K., Lipping S., Virtanen T. Clotho: An audio captioning dataset. *Proc. of the ICASSP 2020 — 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020, pp. 736–740. <https://doi.org/10.1109/icassp40776.2020.9052990>

## References

1. Kriman S., Beliaev S., Ginsburg B., Huang J., Kuchaiev O., Lavrukhin V., Leary R., Li J., Zhang Y. Quartznet: Deep automatic speech recognition with 1D time-channel separable convolutions. *Proc. of the ICASSP 2020 — 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020, pp. 6124–6128. <https://doi.org/10.1109/icassp40776.2020.9053889>
2. Lakhotia K., Kharitonov E., Hsu W.-N., Adi Y., Polyak A., Bolte B., Nguyen T.-A., Copet J., Baevski A., Mohamed A., Dupoux E. On generative spoken language modeling from raw audio. *Transactions of the Association for Computational Linguistics*, 2021, vol. 9, pp. 1336–1354.
3. Gulati A., Qin J., Chiu C.-C., Parmar N., Zhang Y., Yu J., Han W., Wang S., Zhang Z., Wu Y., Pang R. Conformer: Convolution-augmented transformer for speech recognition. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2020, pp. 5036–5040. <https://doi.org/10.21437/interspeech.2020-3015>
4. Hsu W.N., Tsai B., Bolte Y.-H.H., Salakhutdinov R., Mohamed A. HuBERT: How much can a bad teacher benefit ASR pre-training?. *Proc. of the ICASSP 2021 — 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2021, pp. 6533–6537. <https://doi.org/10.1109/icassp39728.2021.9414460>
5. Radford A., Kim J.W., Xu T., Brockman G., McLeavey C., Sutskever I. Robust speech recognition via large-scale weak supervision. *Proceedings of Machine Learning Research*, 2023, vol. 202, pp. 28492–28518.
6. Gong Y., Khurana S., Karlinsky L., Glass J. Whisper-at: Noise-robust automatic speech recognizers are also strong general audio event taggers. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2023, pp. 2798–2802. <https://doi.org/10.21437/interspeech.2023-2193>
7. Panayotov V., Chen G., Povey D., Khudanpur S. Librispeech: an asr corpus based on public domain audio books. *Proc. of the IEEE International Conference On Acoustics, Speech and Signal Processing (ICASSP)*, 2015, pp. 5206–5210. <https://doi.org/10.1109/icassp.2015.7178964>
8. Moritz N., Wichern G., Hori T., Le Roux L. All-in-One transformer: Unifying speech recognition, audio tagging, and event detection. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2020, pp. 3112–3116. <https://doi.org/10.21437/interspeech.2020-2757>
9. Karita S., Soplin N.E.Y., Watanabe S., Delcroix M., Ogawa A., Nakatani T. Improving transformer-based end-to-end speech recognition with connectionist temporal classification and language model integration. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2019, pp. 1408–1412. <https://doi.org/10.21437/interspeech.2019-1938>
10. Chen S., Wu Y., Wang C., Liu S., Tompkins D., Chen Z., Che W., Yu X., Wei F. Beats: Audio pre-training with acoustic tokenizers. *Proceedings of Machine Learning Research*, 2023, vol. 202, pp. 4672–4712.
11. Gemmeke J.F., Ellis D.P.W., Freedman D., Jansen A., Lawrence W., Moore R.C., Plakal M., Ritter M. Audio set: An ontology and human-labeled dataset for audio events. *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2017, pp. 776–780. <https://doi.org/10.1109/icassp.2017.7952261>
12. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. et al. An image is worth 16×16 words: Transformers for image recognition at scale. *Proc. of the ICLR 2021 — 9<sup>th</sup> International Conference on Learning Representations*, 2021.
13. Drossos K., Lipping S., Virtanen T. Clotho: An audio captioning dataset. *Proc. of the ICASSP 2020 — 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020, pp. 736–740. <https://doi.org/10.1109/icassp40776.2020.9052990>

14. Poria S., Hazarika D., Majumder N., Naik G., Cambria E., Mihalcea R. MELD: A multimodal multi-party dataset for emotion recognition in conversations // Proc. of the 57<sup>th</sup> Annual Meeting of the Association for Computational Linguistics. 2019. P. 527–536. <https://doi.org/10.18653/v1/p19-1050>
15. Lipping S., Sudarsanam P., Drossos K., Virtanen T. Clotho-AQA: A crowdsourced dataset for audio question answering // Proc. of the 30<sup>th</sup> European Signal Processing Conference (EUSIPCO). 2022. P. 1140–1144. <https://doi.org/10.23919/eusipco55093.2022.9909680>
16. Engel J., Resnick C., Roberts A., Dieleman S., Norouzi M., Eck D., Simonyan K. Neural audio synthesis of musical notes with wavenet autoencoders // Proceedings Conference on Machine Learning, PMLR. 2017. V. 70. P. 1068–1077.
17. Chu Y., Xu J., Zhou X., Yang Q., Zhang S., Yan Z., Zhou C., Zhou J. Qwen-audio: Advancing universal audio understanding via unified large-scale audio-language models // arXiv. 2023. arXiv:2311.07919. <https://doi.org/10.48550/arXiv.2311.07919>
18. Bai J., Bai S., Chu Y., Cui Z. Qwen technical report // arXiv. 2023. arXiv:2309.16609. <https://doi.org/10.48550/arXiv.2309.16609>
19. Schmid F., Morocutti T., Masoudian S., Koutini K., Widmer G. CP-JKU submission to dcase23: Efficient acoustic scene classification with cp-mobile: Technical Report / Detection and Classification of Acoustic Scenes and Events (DCASE). 2023. 5 p.
20. Salamon J., MacConnell D., Cartwright M., Li P., Bello J.P. Scaper: A library for soundscape synthesis and augmentation // Proc. of the IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA). 2017. P. 344–348. <https://doi.org/10.1109/waspaa.2017.8170052>
21. Tarvainen A., Valpola H. Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results // Advances in Neural Information Processing Systems. 2017. V. 30. P. 1196–1205.
22. Zhang Z., Luo P., Loy C.C., Tang X. Facial landmark detection by deep multi-task learning // Lecture Notes in Computer Science. 2014. V. 8694. P. 94–108. [https://doi.org/10.1007/978-3-319-10599-4\\_7](https://doi.org/10.1007/978-3-319-10599-4_7)
23. Dai J., He K., Sun J. Instance-aware semantic segmentation via multi-task network cascades // Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 3150–3158. <https://doi.org/10.1109/cvpr.2016.343>
24. Zhao X., Li H., Shen X., Liang X., Wu Y. A modulation module for multi-task learning with applications in image retrieval // Lecture Notes in Computer Science. 2018. V. 11205. P. 415–432. [https://doi.org/10.1007/978-3-030-01246-5\\_25](https://doi.org/10.1007/978-3-030-01246-5_25)
25. Liu S., Johns E., Davison A.J. End-to-end multi-task learning with attention // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2019. P. 1871–1880. <https://doi.org/10.1109/cvpr.2019.00197>
26. Ma J., Zhao Z., Yi X., Chen J., Hong L., Chi E.H. Modeling task relationships in multi-task learning with multi-gate mixture-of-experts // Proc. of the 24<sup>th</sup> ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018. P. 1930–1939. <https://doi.org/10.1145/3219819.3220007>
27. Misra I., Shrivastava A., Gupta A., Hebert M. Cross-stitch networks for multi-task learning // Proc. of the IEEE Conference on Computer Vision and Pattern Recognition. 2016. P. 3994–4003. <https://doi.org/10.1109/cvpr.2016.433>
28. Ruder S., Bingel J., Augenstein I., Søgaard A. Latent multi-task architecture learning // Proceedings of the AAAI Conference on Artificial Intelligence. 2019. V. 33. N 01. P. 4822–4829. <https://doi.org/10.1609/aaai.v33i01.33014822>
29. Krause D.A., Mesaros A. Binaural signal representations for joint sound event detection and acoustic scene classification // Proc. of the 30<sup>th</sup> European Signal Processing Conference (EUSIPCO). 2022. P. 399–403. <https://doi.org/10.23919/eusipco55093.2022.9909581>
30. Khandelwal T., Das R.K. A multi-task learning framework for sound event detection using high-level acoustic characteristics of sounds // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2023. P. 1214–1218. <https://doi.org/10.21437/interspeech.2023-909>
31. French R.M. Catastrophic forgetting in connectionist networks // Trends in Cognitive Sciences. 1999. V. 3. N 4. P. 128–135. [https://doi.org/10.1016/s1364-6613\(99\)01294-2](https://doi.org/10.1016/s1364-6613(99)01294-2)
32. McCloskey M., Cohen N.J. Catastrophic interference in connectionist networks: The sequential learning problem // Psychology of Learning and Motivation. 1989. V. 24. P. 109–165. [https://doi.org/10.1016/s0079-7421\(08\)60536-8](https://doi.org/10.1016/s0079-7421(08)60536-8)
- 2020, pp. 736–740. <https://doi.org/10.1109/icassp40776.2020.9052990>
14. Poria S., Hazarika D., Majumder N., Naik G., Cambria E., Mihalcea R. MELD: A multimodal multi-party dataset for emotion recognition in conversations // Proc. of the 57<sup>th</sup> Annual Meeting of the Association for Computational Linguistics. 2019, pp. 527–536. <https://doi.org/10.18653/v1/p19-1050>
15. Lipping S., Sudarsanam P., Drossos K., Virtanen T. Clotho-AQA: A crowdsourced dataset for audio question answering // Proc. of the 30<sup>th</sup> European Signal Processing Conference (EUSIPCO). 2022, pp. 1140–1144. <https://doi.org/10.23919/eusipco55093.2022.9909680>
16. Engel J., Resnick C., Roberts A., Dieleman S., Norouzi M., Eck D., Simonyan K. Neural audio synthesis of musical notes with wavenet autoencoders // International Conference on Machine Learning, PMLR. 2017, vol. 70, pp. 1068–1077.
17. Chu Y., Xu J., Zhou X., Yang Q., Zhang S., Yan Z., Zhou C., Zhou J. Qwen-audio: Advancing universal audio understanding via unified large-scale audio-language models // arXiv. 2023, arXiv:2311.07919. <https://doi.org/10.48550/arXiv.2311.07919>
18. Bai J., Bai S., Chu Y., Cui Z. Qwen technical report // arXiv. 2023, arXiv:2309.16609. <https://doi.org/10.48550/arXiv.2309.16609>
19. Schmid F., Morocutti T., Masoudian S., Koutini K., Widmer G. CP-JKU submission to dcase23: Efficient acoustic scene classification with cp-mobile: Technical Report / Detection and Classification of Acoustic Scenes and Events (DCASE). 2023. 5 p.
20. Salamon J., MacConnell D., Cartwright M., Li P., Bello J.P. Scaper: A library for soundscape synthesis and augmentation // Proc. of the IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA). 2017, pp. 344–348. <https://doi.org/10.1109/waspaa.2017.8170052>
21. Tarvainen A., Valpola H. Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results // Advances in Neural Information Processing Systems, 2017, vol. 30, pp. 1196–1205.
22. Zhang Z., Luo P., Loy C.C., Tang X. Facial landmark detection by deep multi-task learning // Lecture Notes in Computer Science, 2014, vol. 8694, pp. 94–108. [https://doi.org/10.1007/978-3-319-10599-4\\_7](https://doi.org/10.1007/978-3-319-10599-4_7)
23. Dai J., He K., Sun J. Instance-aware semantic segmentation via multi-task network cascades // Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 3150–3158. <https://doi.org/10.1109/cvpr.2016.343>
24. Zhao X., Li H., Shen X., Liang X., Wu Y. A modulation module for multi-task learning with applications in image retrieval // Lecture Notes in Computer Science, 2018, vol. 11205, pp. 415–432. [https://doi.org/10.1007/978-3-030-01246-5\\_25](https://doi.org/10.1007/978-3-030-01246-5_25)
25. Liu S., Johns E., Davison A.J. End-to-end multi-task learning with attention // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, pp. 1871–1880. <https://doi.org/10.1109/cvpr.2019.00197>
26. Ma J., Zhao Z., Yi X., Chen J., Hong L., Chi E.H. Modeling task relationships in multi-task learning with multi-gate mixture-of-experts // Proc. of the 24<sup>th</sup> ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018, pp. 1930–1939. <https://doi.org/10.1145/3219819.3220007>
27. Misra I., Shrivastava A., Gupta A., Hebert M. Cross-stitch networks for multi-task learning // Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, pp. 3994–4003. <https://doi.org/10.1109/cvpr.2016.433>
28. Ruder S., Bingel J., Augenstein I., Søgaard A. Latent multi-task architecture learning // Proceedings of the AAAI Conference on Artificial Intelligence, 2019, vol. 33, no. 01, pp. 4822–4829. <https://doi.org/10.1609/aaai.v33i01.33014822>
29. Krause D.A., Mesaros A. Binaural signal representations for joint sound event detection and acoustic scene classification // Proc. of the 30<sup>th</sup> European Signal Processing Conference (EUSIPCO), 2022, pp. 399–403. <https://doi.org/10.23919/eusipco55093.2022.9909581>
30. Khandelwal T., Das R.K. A multi-task learning framework for sound event detection using high-level acoustic characteristics of sounds // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH, 2023, pp. 1214–1218. <https://doi.org/10.21437/interspeech.2023-909>
31. French R.M. Catastrophic forgetting in connectionist networks // Trends in Cognitive Sciences, 1999, vol. 3, no. 4, pp. 128–135. [https://doi.org/10.1016/s1364-6613\(99\)01294-2](https://doi.org/10.1016/s1364-6613(99)01294-2)
32. McCloskey M., Cohen N.J. Catastrophic interference in connectionist networks: The sequential learning problem // Psychology of Learning and Motivation, 1989, vol. 24, pp. 109–165. [https://doi.org/10.1016/s0079-7421\(08\)60536-8](https://doi.org/10.1016/s0079-7421(08)60536-8)

33. Kirkpatrick J., Pascanu R., Rabinowitz N., Veness J., Desjardins G., Rusu A.A., Milan K., Quan J., Ramalho T., Grabska-Barwinska A., Hassabis D., Clopath C., Kumaran D., Hadsell R. Overcoming catastrophic forgetting in neural networks // Proceedings of the national academy of sciences. 2017. V. 114. N 13. P. 3521–3526. <https://doi.org/10.1073/pnas.1611835114>
34. Kim J.W., Lee G.W., Kim H.K., Seo Y.S., Song I.H. Semi-supervised learning-based sound event detection using frequency-channel-wise selective kernel for DCASE challenge 2022 Task 4: Technical Report / Detection and Classification of Acoustic Scenes and Events (DCASE), 2022. 4 p.
33. Kirkpatrick J., Pascanu R., Rabinowitz N., Veness J., Desjardins G., Rusu A.A., Milan K., Quan J., Ramalho T., Grabska-Barwinska A., Hassabis D., Clopath C., Kumaran D., Hadsell R. Overcoming catastrophic forgetting in neural networks. *Proceedings of the national academy of sciences*, 2017, vol. 114, no. 13, pp. 3521–3526. <https://doi.org/10.1073/pnas.1611835114>
34. Kim J.W., Lee G.W., Kim H.K., Seo Y.S., Song I.H. *Semi-supervised learning-based sound event detection using frequency-channel-wise selective kernel for DCASE challenge 2022 Task 4: Technical Report. Detection and Classification of Acoustic Scenes and Events (DCASE)*, 2022, 4 p.

### Автор

**Сурков Максим Константинович** — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-3929-7484>, surkovmax007@mail.ru

### Author

**Maxim K. Surkov** — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-3929-7484>, surkovmax007@mail.ru

Статья поступила в редакцию 20.06.2024  
Одобрена после рецензирования 07.07.2024  
Принята к печати 27.09.2024

Received 20.06.2024  
Approved after reviewing 07.07.2024  
Accepted 27.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-770-778  
 УДК 004.89

## Метод оптимизации нейронных сетей на основе структурной дистилляции с применением генетического алгоритма

Владимир Никифорович Кузьмин<sup>1</sup>, Артем Бакытжанович Менисов<sup>2✉</sup>,  
 Тимур Римович Сабиров<sup>3</sup>

<sup>1,2,3</sup> Военно-космическая академия имени А.Ф.Можайского, Санкт-Петербург, 197198, Российская Федерация

<sup>1</sup> vka@mil.ru, <https://orcid.org/0000-0002-6411-4336>

<sup>2</sup> vka@mil.ru✉, <https://orcid.org/0000-0002-9955-2694>

<sup>3</sup> vka@mil.ru, <https://orcid.org/0000-0002-6807-2954>

### Аннотация

**Введение.** По мере усложнения нейронных сетей увеличивается количество параметров и необходимых вычислений, что затрудняет установку и эксплуатацию систем искусственного интеллекта на периферийных устройствах. Структурная дистилляция может существенно сократить ресурсоемкость применения любых нейронных сетей. **Метод.** В работе представлен метод оптимизации нейронных сетей, который сочетает в себе преимущества структурной дистилляции и генетического алгоритма. В отличие от эволюционных подходов, используемых при поиске оптимальной архитектуры или дистилляции нейронных сетей, при формировании вариантов дистилляции предлагается кодировать не только параметры нейронной сети, но и связи между нейронами. **Основные результаты.** Экспериментальное исследование проводилось на моделях VGG16 и ResNet18 с использованием набора данных CIFAR-10. Показано, что структурная дистилляция позволяет оптимизировать размер нейронных сетей, сохраняя их обобщающую способность, а генетический алгоритм используется для эффективного поиска оптимальных вариантов дистилляции нейронных сетей, учитывая их структурную сложность и производительность. **Обсуждение.** Полученные результаты продемонстрировали эффективность предложенного метода при уменьшении размеров и улучшении производительности сетей с допустимой потерей качества.

### Ключевые слова

искусственный интеллект, нейронные сети, структурная дистилляция, генетический алгоритм

**Ссылка для цитирования:** Кузьмин В.Н., Менисов А.Б., Сабиров Т.Р. Метод оптимизации нейронных сетей на основе структурной дистилляции с применением генетического алгоритма // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 770–778. doi: 10.17586/2226-1494-2024-24-5-770-778

## A method for optimizing neural networks based on structural distillation using a genetic algorithm

Vladimir N. Kuzmin<sup>1</sup>, Artem B. Menisov<sup>2✉</sup>, Timur R. Sabirov<sup>3</sup>

<sup>1,2,3</sup> Mozhaisky Military Aerospace Academy, Saint Petersburg, 197198, Russian Federation

<sup>1</sup> vka@mil.ru, <https://orcid.org/0000-0002-6411-4336>

<sup>2</sup> vka@mil.ru✉, <https://orcid.org/0000-0002-9955-2694>

<sup>3</sup> vka@mil.ru, <https://orcid.org/0000-0002-6807-2954>

### Abstract

As neural networks become more complex, the number of parameters and required computations increases, which complicates the installation and operation of artificial intelligence systems on edge devices. Structural distillation can significantly reduce the resource intensity of using any neural networks. The paper presents a method for optimizing neural networks that combines the advantages of structural distillation and a genetic algorithm. Unlike evolutionary approaches used to search for the optimal architecture or distillation of neural networks, when forming distillation

© Кузьмин В.Н., Менисов А.Б., Сабиров Т.Р., 2024

options, it is proposed to encode not only the parameters of the neural network, but also the connections between neurons. The experimental study was conducted on the VGG16 and ResNet18 models using the CIFAR-10 dataset. It is shown that structural distillation allows optimizing the size of neural networks while maintaining their generalizing ability, and the genetic algorithm is used to effectively search for optimal distillation options for neural networks, taking into account their structural complexity and performance. The obtained results demonstrated the effectiveness of the proposed method in reducing the size and improving the performance of networks with an acceptable loss of quality.

#### Keywords

artificial intelligence, neural networks, structural distillation, genetic algorithm

**For citation:** Kuzmin V.N., Menisov A.B., Sabirov T.R. A method for optimizing neural networks based on structural distillation using a genetic algorithm. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 770–778 (in Russian). doi: 10.17586/2226-1494-2024-24-5-770-778

## Введение

Современные искусственные нейронные сети (ИНС) могут включать сотни слоев и позволяют добиваться высоких результатов в решении различных задач, например, таких как распознавание и классификация объектов на изображениях [1]. Однако по мере увеличения сложности нейронных сетей (число слоев) объем вычислений резко возрастает [2]. Это выдвигает более высокие требования к информационной инфраструктуре эксплуатации ИНС. Соответственно, для некоторых прикладных задач сложно внедрить ИНС, когда вычислительная мощность и энергопотребление ограничены [3]. Это особенно актуально при увеличении сложности ИНС. Например, широко используемая сверточная нейронная сеть ResNet50 [4] занимает более 95 МБ памяти для хранения, содержит более 23 млн параметров и требует 4 GFLOP для вычислений. Модель GPT-3 содержит 175 млрд параметров [5], а GPT-4 — 1,76 трлн [6].

Разработка нейронных сетей является одновременно ключевым и сложным процессом в создании систем искусственного интеллекта, связанным с поиском оптимальной архитектуры, которая соответствует прикладной задаче, данным и, как следствие, дает наилучший результат. Поиск архитектуры нейронной сети (Neural Architecture Search, NAS) заключается в определении наилучшей топологии для решаемой задачи.

Основной причиной оптимизации готовых архитектур нейронных сетей является снижение ее сложности. Исследования в области NAS предлагают искать структуры нейронных сетей в порядке возрастания их уровня сложности и базируются на обучении с подкреплением или эвристических подходах. Исходя из ограничений этих подходов, заключающихся в полном поиске для каждой спецификации развертывания оборудования или цели, применение эволюционных алгоритмов стоит обобщить следующей последовательностью: инициализация из начальных вариантов архитектур (вручную); применение операторов эволюционного алгоритма для создания новых архитектур; эксплуатация, при которой используются знания, хранящиеся в истории всех оцененных архитектур.

Такая последовательность NAS применяется для построения модели машинного обучения с нуля (с примитивами низкого уровня для комбинирования признаков и обучения нейронов), которая способна получить относительно лучшую производительность для решаемой задачи.

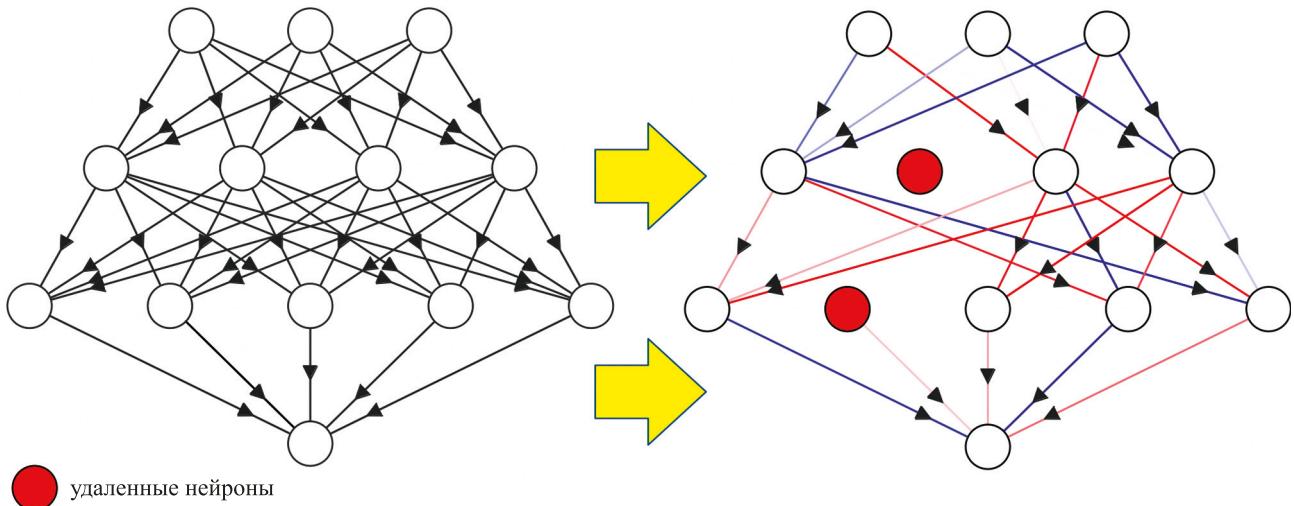
Однако одним из самых популярных способов снижения сложности нейронной сети является дистилляция (обрезка). Цель дистилляции — удалить часть параметров нейронной сети, чтобы они не участвовали в процессе обучения и/или вывода. В работах [7–14] изучена дистилляция нейронных сетей, которая включает основные типы: структурированная и неструктурированная дистилляции.

Методы неструктурированной дистилляции удаляют веса без соблюдения какого-либо порядка. Для методов структурированной — формируются критерии и ограничения, которые определяют, как будет выполнена дистилляция. Среди всех методов выделяются критерии обрезки нейронов на основе значений их весов. Логика, лежащая в основе этих методов обрезки, проста: определенное количество или долю от всех весов нейронов, которые вносят меньший вклад в обученную модель, удаляется из архитектуры. Это ускоряет выполнение вывода и наделяет ее лучшими возможностями обобщения. Однако многократные этапы обрезки продемонстрировали [9], что она приводит к снижению производительности модели. Кроме того, можно так сократить всю модель, изменяя всю архитектуру и сделать предварительно обученные параметры непригодными для использования [8].

В работе [7] обнаружено, что в ИНС может существовать избыточность элементов, что обуславливает возможность и целесообразность оптимизации архитектуры ИНС — снижение ее сложности. Кроме того, избыточность элементов (нейронов) ИНС может снижать их надежность, повышая риск состязательных атак [8]. При структурной дистилляции возможно не только развернуть ИНС на устройстве с ограниченными ресурсами, но и сохранить при этом ее производительность [9]. Такой процесс состоит из этапов оценивания важности параметров ИНС и их селективном удалении, чтобы они не участвовали в обучении и/или выводе — по сути, их обнулении (рис. 1).

Параллельно, с удалением нейронов ИНС, может значительно улучшиться состязательная устойчивость. Это особенно актуально, так как в условиях обеспечения безопасности ИНС и ограниченности ресурсов одновременно необходимы надежность и компактность нейронных сетей [10].

Все работы в направлении дистилляции ИНС показали, что большие сети можно свести к гораздо меньшим подсетям, сохранив при этом их качество функционирования [11]. Отметим, что подходы к структурной дистилляции ИНС охватывают ряд аспектов, включая



*Рис. 1. Пример структурной дистилляции искусственной нейронной сети (насыщенность стрелок определяет значение весов сети, красный цвет — положительная связь, синий — отрицательная)*

*Fig. 1. Example of structural distillation of artificial neural network (the arrows saturation determines the value of the network weights, red color is a positive connection, blue is a negative one)*

схемы удаления нейронов и связей [12], выбор параметров [13] и методов обучения ИНС [14]. К сожалению, существующие решения по-прежнему зависят от эмпирических правил или заранее определенных архитектурных шаблонов, что делает их недостаточно универсальными.

Одним из таких успешных подходов является удаление отдельных нейронов на основе их весов, т. е. обладающих весом ниже определенного порога. На практике этот порог обычно определяется путем сравнения весов внутри каждого уровня или глобально по всей сети. Однако многочисленные этапы сокращения показали, что необходим плановый метод структурной дистилляции ИНС, который предполагает, что на ранних стадиях обучения ИНС можно удалить большее число нейронов, в то время как на поздних стадиях следует систематически сокращать число обнуленных весов.

### Формализация процесса структурной дистилляции ИНС

Формализованное описание структурной дистилляции ИНС может быть представлено следующим образом.

Пусть дана ИНС с архитектурой  $\mathbb{N}$  и параметрами  $W$ . Цель состоит в том, чтобы найти оптимальный вектор-индикатор  $c$ , который указывает, какие нейроны следует удалить из сети, чтобы минимизировать некоторую функцию потерь  $L$  при сохранении определенного уровня производительности модели.

Формально, задача оптимизации удаления нейронов может быть описана как:

$$\min_c L(\mathbb{N}(W \odot c)), \quad (1)$$

где  $\mathbb{N}(W \odot c)$  — нейронная сеть с параметрами  $W$ , в которых веса, соответствующие неактивным нейронам, обнулены;  $L$  — функция потерь, которая зависит от

производительности ИНС на некотором наборе данных;  $\odot$  — поэлементное умножение матриц;  $c$  — бинарный вектор-индикатор, где  $c_j = 1$  указывает, что  $j$ -й нейрон активен, и  $c_j = 0$  —  $j$ -й нейрон удален.

Таким образом, вектор-индикатор с позволяет сформировать дистиллируемую нейронную сеть  $\mathbb{N}_c = \bigcup_{i=1}^n \bigcup_{j=1}^{l_i} c_{ij} l_i$  с детализацией каждого слоя. Когда  $c_{ij} = 1$  для любых  $i$  и  $j$ , то  $\mathbb{N}_c$  на самом деле является исходной сетью  $\mathbb{N}$ .

Таким образом, цель дистилляции состоит в том, чтобы найти такой вектор-индикатор  $c$ , который обеспечивает наилучшую производительность ИНС и минимизирует вычислительные затраты обрезанной сети  $\mathbb{N}_c$ . Используя число операций с плавающей точкой в секунду (FLOPS), которое является общей метрикой, для измерения вычислительных затрат, задача дистилляции будет определена в виде:

$$\operatorname{argmax}_{c \in \{0,1\}} (F(\mathbb{N}_c), FLOPS(\mathbb{N}_c)). \quad (2)$$

### Описание этапов метода структурной дистилляции ИНС

Реализованная методическая схема структурной дистилляции ИНС включает удаление нейронов на основе оценки их чувствительности и вклада в качество функционирования ИНС. Основное правило состоит в том, чтобы исключить нейроны с наименьшей чувствительностью, сводя к минимуму их влияние на производительность ИНС. Этот процесс сокращения элементов приводит к оптимизации сети, снижая сложность, вычислительные требования и время обработки. Однако при обрезке ИНС необходимо проявлять осторожность, поскольку чрезмерное удаление нейронов может отрицательно повлиять на производительность сети. Таким образом, поддержание баланса между удалением и производительностью ИНС имеет решающее значение

в процессе оптимизации, чтобы предотвратить потерю критической информации.

Использование генетических алгоритмов (ГА) [15] для структурной дистилляции ИНС включает в себя три основных особенности: биоинспирированный подход, позволяющий закодировать архитектуру нейронной сети в вектор хромосомы; с помощью ГА можно быстро найти субоптимальную стратегию удаления нейронов; для ГА не требуется информации о гиперпараметрах обучения ИНС.

Таким образом, ГА<sup>1</sup> при поиске оптимальной стратегии структурной дистилляции ИНС одновременно ищет набор оптимальных весов нейронов в популяции в каждом поколении, что приводит к уменьшению размеров ИНС.

Структурная дистилляция ИНС с использованием ГА может быть достигнута следующим образом.

**Этап 1. Инициализация начальной популяции.** Каждый индивид для ГА представляет собой некоторую комбинацию хромосом (нейронов и связей).

Опишем варианты кодировки структуры ИНС для нейронов и связей (рис. 2).

- Нейроны: каждый ген хромосомы представляет совокупность активных нейронов. Значение 1 в позиции  $j$  означает, что нейрон  $j$  активен, а значение 0 — неактивен. Неактивный нейрон подразумевает, что все входные соединения удаляются как во время обучения, так и во время вывода. Длина хромосомы в данном случае равна числу нейронов слоя ИНС.
- Связи: каждый ген представляет связь между слоями. Интерпретация двоичных значений следующая: если ген равен 1, связь между соответствующими слоями существует. Длина хромосомы — множество связей между нейронами соседних слоев ИНС.

**Этап 2. Оценка приспособленности.** Каждый вариант удаления нейронов (хромосомы) оценивается на основе производительности на некотором тестовом наборе данных. Производительность может быть изменена, например, точностью классификации, среднеквадратичной ошибкой или значением функции потерь.

**Этап 3. Селекция.** Хромосомы с наилучшими значениями фитнес-функции выбираются для дальнейшей обработки с использованием операторов скрещивания и мутации. Для данного исследования будем считать фитнес-функцию определенной в выражении (1).

**Этап 4. Скрещивание.** Выполняется скрещивание выбранных вариантов ИНС, чтобы создать новое поколение. В результате скрещивания создаются новые комбинации генов, которые сочетают признаки родителей  $A = \{a_i | i = 1, \dots, n_{last\_layer}\}$  и  $B = \{b_i | i = 1, \dots, n_{last\_layer}\}$ , и величиной  $p_c$  в диапазоне  $[0, 1]$ , которая определяет точку разрыва кодировки связей ИНС.

<sup>1</sup> Основные термины, используемые в ГА и адаптированные для структурной дистилляции ИНС: ген — блок сети, выполняющий некоторую функцию над входными данными (когда геном является нейроном, функция представляет собой некоторую функцию активации, например, ReLU); хромосома — представляет собой всю ИНС с нейронами и их связями; особь — виртуальный организм с хромосомами; популяция — совокупность особей.

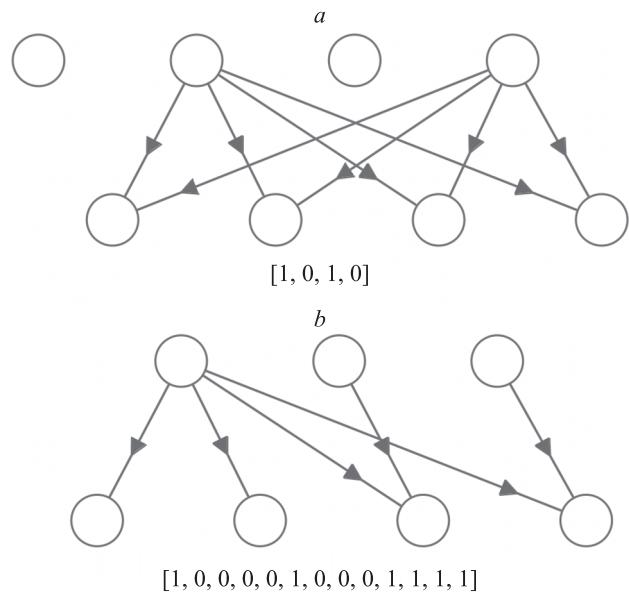


Рис. 2. Варианты кодировки структуры искусственной нейронной сети для нейрона (a) и связей (b)

Fig. 2. Options for encoding the artificial neural network structure: for a neuron (a); for connections (b)

**Этап 5. Мутация.** С вероятностью  $p_{mut}$  каждый хромосома изменяется случайным образом. Оператор мутации предотвращает остановку ГА в локальных оптимумах.

**Этап 6. Оценивание приспособленности новых вариантов обрезки ИНС.** Новое поколение оценивается на том же тестовом наборе данных, что и предыдущее, чтобы определить их приспособленность.

**Этап 7. Повторение процесса.** Этапы селекции, скрещивания, мутации и оценки приспособленности повторяются до тех пор, пока не будет достигнуто условие остановки (например, определенное число поколений или сходимость к определенному уровню функции потерь).

**Этап 8. Отбор лучших вариантов.** После завершения процесса отбираются индивиды с наилучшей приспособленностью в конечную популяцию. Полученная оптимальная комбинация нейронов и связей применяется для дистилляции исходной нейронной сети.

## Эксперимент

Оценивание разработанного метода обрезки выполнено на нейронных сетях VGG16 [16] и ResNet18 [17], характеристики которых представлены в табл. 1, и валидационной части набора данных CIFAR-10 [18].

CIFAR-10 — набор данных, состоящий из 60 000 изображений, 50 000 для обучения и 10 000 для тестирования. Он разделен на 10 классов, и каждый класс содержит 5000 обучающих и 1000 тестовых изображений. Каждый объект CIFAR-10 представляет собой RGB-изображение размером  $32 \times 32$  пикселя. Этот набор данных широко используется для классификации изображений и является одним из самых известных эталонных наборов данных в области компьютерного зрения.

*Таблица 1.* Исходные нейронные сети для эксперимента*Table 1.* Initial neural networks for the experiment

Наименование предобученной ИНС	Число параметров	Число слоев	Объем памяти, МБ
VGG16	14 849 345	16	56,13
ResNet18	11 689 512	72	57,42

Настройки гиперпараметров ГА следующие: размер популяции  $N = 30$ , число выбранных геномов  $K = 5$ , параметр скрещивания  $p_c = 0,6$ , параметр мутаций  $p_{mut} = 0,6$ , число раундов  $T = 5$ .

Рассмотрим результаты структурной дистилляции ИНС (табл. 2) и изменение параметров ГА, которые влияют на результаты вычислений (табл. 3).

### Обсуждение результатов эксперимента

Из результатов экспериментов следует, что ГА позволил значительно уменьшить число параметров в обеих ИНС при сохранении приемлемого уровня точности.

Несмотря на структурную дистилляцию, качество на тестовом наборе данных осталось высоким. Это

*Таблица 2.* Результаты эксперимента*Table 2.* Experiment results

Раунд ГА	Число параметров, млн	Объем памяти, МБ	Точность (для топ-1)	Доля уменьшения параметров ИНС, %	FLOPS · 10 <sup>6</sup>
VGG16					
1	13,2	53,438	0,8571	7	60,1
2	3,1	11,882	0,8597	21	48,5
3	0,9	3,578	0,8551	29	40,8
4	0,5	1,787	0,8473	55	29,5
5	0,3	1,243	0,8374	60	11,2
ResNet18					
1	11,2	42,707	0,7223	5	1,800
2	3,0	11,529	0,7213	26	1,080
3	0,9	3,591	0,7223	30	0,736
4	0,3	1,218	0,7234	33	0,590
5	0,1	0,460	0,6558	33	0,502

*Таблица 3.* Результаты вычислений генетического алгоритма*Table 3.* Genetic algorithm calculation results

Раунд ГА	Время работы, с	Результат (значение целевой функции) <sup>1</sup>
VGG16		
1	543,81	0,8571; 60,1
2	491,52	0,8597; 48,5
3	488,79	0,8551; 40,8
4	246,66	0,8473; 29,5
5	219,34	0,8374; 11,2
ResNet18		
1	367,83	0,7223; 1,800
2	332,46	0,7213; 1,080
3	330,61	0,7223; 0,736
4	166,83	0,7234; 0,590
5	148,36	0,6558; 0,502

<sup>1</sup> Выражение (2).

Таблица 4. Рейтинг и характеристики нейронных сетей, обученных на наборе данных CIFAR-10

Table 4. Ranking and characteristics of neural networks trained on the CIFAR-10 dataset

Название ИНС	Точность (для топ-1)	Время обучения, с
UL-Hopfield [19]	0,8310	998,27
CvP [20]	0,8319	692,22
CCN [20]	0,8336	743,94
ThresholdNet [21]	0,8528	1014,47

Таблица 5. Результаты удаления нейронов при ГА для ИНС VGG16 и ResNet18 (число параметров ИНС, ед.)

Table 5. Results of neuron removal during GA for ANN VGG16 and ResNet18 (number of ANN parameters, units)

Сверточные слои ИНС	Раунды дистилляции				
	1	2	3	4	5
VGG16					
Conv 1	64	39	24	15	9
Conv 2	64	52	42	34	28
Conv 3	128	116	105	95	86
Conv 4	128	122	116	111	106
Conv 5	256	231	208	188	170
Conv 6	256	128	64	32	16
Conv 7	256	128	64	32	16
Conv 8	512	205	82	33	14
Conv 9	512	205	82	33	14
Conv 10	512	205	82	33	14
Conv 11	512	205	82	33	14
Conv 12	512	205	82	33	14
Conv 13	512	205	82	33	14
ResNet18					
Conv 1	64	53	44	36	30
Conv 2	64	58	53	48	44
Conv 3	64	53	44	36	30
Conv 4	64	58	53	48	44
Conv 5	64	53	44	36	30
Conv 6	128	103	83	67	54
Conv 7	128	83	54	36	24
Conv 8	128	83	54	36	24
Conv 9	128	103	83	67	54
Conv 10	128	83	54	36	24
Conv 11	256	205	164	132	106
Conv 12	256	164	106	68	44
Conv 13	256	164	106	68	44
Conv 14	256	205	164	132	106
Conv 15	256	164	106	68	44
Conv 16	512	359	252	177	124
Conv 17	512	252	124	61	31
Conv 18	512	252	124	61	31

свидетельствует о том, что ГА правильно определял нейроны, чье удаление не сильно влияло на способность ИНС к определению класса изображения.

Выполним сравнение временных затрат на генетическую оптимизацию и обучение новых сетей с меньшим числом параметров и слоев, но с таким же качеством. В табл. 4 представлены рейтинг и характеристики нейронных сетей, обученных на наборе данных CIFAR-10<sup>1</sup>.

Из времени обучения ИНС видно, что более оперативно провести дистилляцию нейронной сети, с последующим снижением сложности и необходимых ресурсов, чем обучать новые нейронные сети.

Таким образом, ГА предпочитает удалять нейроны, которые имеют меньшее влияние на вывод ИНС или которые могут быть скомпенсированы другими нейронами в сети. Это позволяет сохранить основные паттерны и зависимости, зафиксированные нейронной сетью в процессе обучения. Перед удалением нейронов ГА может оценивать влияние этого действия на производительность модели с помощью валидационного набора данных. Удаление является неравномерным и касается только сверточных слоев ИНС. Для ИНС VGG16 и ResNet18 изменения за 5 раундов ГА представлены в табл. 5.

Отметим, что предположение о возможности недопустимого снижения качества ИНС не оправдано. Удаление нейронов может даже способствовать более обобщенному обучению ИНС, поскольку это может предотвратить переобучение за счет сокращения ее параметров и упрощения аппроксимирующей функции.

Таким образом, высокое качество предсказаний на тестовом наборе данных после структурной дистилляции ИНС ГА свидетельствует о том, что удаление нейронов было выполнено эффективно. ИНС остается способной к обобщению новых данных и сохранению высокой точности предсказаний, что делает метод пригодным для уменьшения размера ИНС при минимальной потере качества.

Такие результаты подчеркивают значимость ГА для структурной дистилляции ИНС, особенно когда важно

<sup>1</sup>Рейтинг представлен на основе данных ресурса paperswithcode [Электронный ресурс]. Режим доступа: <https://paperswithcode.com/sota/image-classification-on-cifar-10> (дата обращения: 13.05.2024).

## Литература

1. Spoorthi M., Indu Priya B., Kuppala M., Karpe V.S., Dharavath D. Automated resume classification system using ensemble learning // Proc. of the 9<sup>th</sup> International Conference on Advanced Computing and Communication Systems (ICACCS). V. 1. 2023. P. 1782–1785. <https://doi.org/10.1109/icaccs57279.2023.10112917>
2. Freire P.J., Osadchuk Y., Spinnler B., Napoli A., Schairer W., Costa N., Prilepsky J.E., Turitsyn S.K. Performance versus complexity study of neural network equalizers in coherent optical systems // Journal of Lightwave Technology. 2021. V. 39. N 19. P. 6085–6096. <https://doi.org/10.1109/jlt.2021.3096286>
3. Hankala T., Hannula M., Kontinen J., Virtema J. Complexity of neural network training and ETR: Extensions with effectively continuous functions // Proceedings of the AAAI Conference on Artificial

сохранить высокую точность предсказаний при одновременном сокращении вычислительной нагрузки.

Для более крупных ИНС, таких как большие языковые и мультимодальные ИНС, применение ГА для структурной дистилляции может иметь еще более значимые результаты, заключающиеся в следующем.

- Экономия ресурсов. Большие языковые и мультимодальные ИНС обычно требуют огромного количества вычислительных ресурсов для обучения и инференса. Уменьшение размера позволяет снизить требования к ресурсам, что делает их более доступными для широкого круга пользователей и применений.
- Ускорение инференса. Уменьшение размера ИНС также приводит к увеличению скорости инференса, что особенно важно в приложениях реального времени.

Сохранение высокой точности предсказаний. Для ИНС, обученных на огромных корпусах текста, сохранение точности предсказаний является критическим, поскольку они должны обладать высоким пониманием языка для успешного выполнения различных задач, таких как генерация текста или ответ на вопросы. В случае с мультимодальными ИНС, которые обрабатывают как текст, так и изображения или другие типы данных, точность предсказаний также является важным аспектом.

## Заключение

В настоящей работе представлен новый метод оптимизации нейронных сетей, основанный на структурной дистилляции с использованием генетического алгоритма. Эксперименты на моделях VGG16 и ResNet18 показали, что предложенный метод способен существенно оптимизировать размер архитектуры сетей, сохраняя при этом их производительность. Полученные результаты подтверждают эффективность метода в оптимизации нейронных сетей и его потенциал в применении к другим моделям и задачам машинного обучения. В будущем планируется расширить область применения метода на более широкий спектр архитектур и наборов данных, провести более глубокий анализ его характеристик и преимуществ, а также экспериментально доказать закономерности сокращения сложности отдельных слоев при адаптации сокращенных нейронных сетей для других задач.

## References

1. Spoorthi M., Indu Priya B., Kuppala M., Karpe V.S., Dharavath D. Automated resume classification system using ensemble learning. *Proc. of the 9<sup>th</sup> International Conference on Advanced Computing and Communication Systems (ICACCS). V. 1*, 2023, pp. 1782–1785. <https://doi.org/10.1109/icaccs57279.2023.10112917>
2. Freire P.J., Osadchuk Y., Spinnler B., Napoli A., Schairer W., Costa N., Prilepsky J.E., Turitsyn S.K. Performance versus complexity study of neural network equalizers in coherent optical systems. *Journal of Lightwave Technology*, 2021, vol. 39, no. 19, pp. 6085–6096. <https://doi.org/10.1109/jlt.2021.3096286>
3. Hankala T., Hannula M., Kontinen J., Virtema J. Complexity of neural network training and ETR: Extensions with effectively continuous functions. *Proceedings of the AAAI Conference on Artificial*

- Intelligence. 2024. V. 38. N 11. P. 12278–12285. <https://doi.org/10.1609/aaai.v38i11.29118>
4. Koonce B., Koonce B. ResNet 50 // Convolutional Neural Networks with Swift for Tensorflow: Image Recognition and Dataset Categorization. Springer, 2021. P. 63–72. [https://doi.org/10.1007/978-1-4842-6168-2\\_6](https://doi.org/10.1007/978-1-4842-6168-2_6)
  5. Floridi L., Chiriatti M. GPT-3: Its nature, scope, limits, and consequences // Minds and Machines. 2020. V. 30. N 4. P. 681–694. <https://doi.org/10.1007/s11023-020-09548-1>
  6. Achiam J., Adler S., Agarwal S. et al. Gpt-4 technical report // arXiv. 2023. arXiv:2303.08774. <https://doi.org/10.48550/arXiv.2303.08774>
  7. Bodimani M. Assessing the impact of transparent AI systems in enhancing user trust and privacy // Journal of Science & Technology. 2024. V. 5. N 1. P. 50–67. <https://doi.org/10.55662/JST.2024.5102>
  8. Lu Z., Li Z., Chiang C.-W., Yin M. Strategic adversarial attacks in AI-assisted decision making to reduce human trust and reliance // Proc. of the Thirty-Second International Joint Conference on Artificial Intelligence. 2023. P. 3020–3028. <https://doi.org/10.24963/ijcai.2023/337>
  9. He Y., Xiao L. Structured pruning for deep convolutional neural networks: A survey // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2024. V. 46. N 5. P. 2900–2919. <https://doi.org/10.1109/tpami.2023.3334614>
  10. Ding S., Zhang L., Pan M., Yuan X. PATROL: Privacy-oriented pruning for collaborative inference against model inversion attacks // Proc. of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). 2024. P. 4704–4713. <https://doi.org/10.1109/wacv57701.2024.00465>
  11. Fang G., Ma X., Song M., Mi M.B., Wang X. Depgraph: Towards any structural pruning // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2023. P. 16091–16101. <https://doi.org/10.1109/cvpr52729.2023.01544>
  12. Wen L., Zhang X., Bai H., Xu Z. Structured pruning of recurrent neural networks through neuron selection // Neural Networks. 2020. V. 123. P. 134–141. <https://doi.org/10.1016/j.neunet.2019.11.018>
  13. Zhao M., Peng J., Yu S., Liu L., Wu N. Exploring structural sparsity in CNN via selective penalty // IEEE Transactions on Circuits and Systems for Video Technology. 2022. V. 32. N 3. P. 1658–1666. <https://doi.org/10.1109/tcsvt.2021.3071532>
  14. Shen M., Molchanov P., Yin H., Alvarez J.M. When to prune? a policy towards early structural pruning // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 12237–12246. <https://doi.org/10.1109/cvpr52688.2022.01193>
  15. Katoch S., Chauhan S.S., Kumar V. A review on genetic algorithm: past, present, and future // Multimedia Tools and Applications. 2021. V. 80. P. 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>
  16. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // arXiv. 2014. arXiv:1409.1556. <https://doi.org/10.48550/arXiv.1409.1556>
  17. Zhou Y., Ren F., Nishide S., Kang X. Facial sentiment classification based on resnet-18 model // Proc. of the 2019 International Conference on Electronic Engineering and Informatics (EEI). 2019. P. 463–466. <https://doi.org/10.1109/eei48997.2019.00106>
  18. Recht B., Roelofs R., Schmidt L., Shankar V. Do CIFAR-10 classifiers generalize to CIFAR-10? // arXiv. 2018. arXiv:1806.00451. <https://doi.org/10.48550/arXiv.1806.00451>
  19. Liu Q., Mukhopadhyay S. Unsupervised learning using pretrained CNN and associative memory bank // Proc. of the International Joint Conference on Neural Networks (IJCNN). 2018. P. 01–08. <https://doi.org/10.1109/ijcnn.2018.8489408>
  20. Jeevan P., Sethi A. Vision Xformers: Efficient attention for image classification // arXiv. 2021. arXiv:2107.02239. <https://doi.org/10.48550/arXiv.2107.02239>
  21. Hou Y., Wu Z., Cai X., Zhu T. The application of improved densenet algorithm in accurate image recognition // Scientific Reports. 2024. V. 14. N 1. P. 8645. <https://doi.org/10.1038/s41598-024-58421-z>
  22. Floridi L., Chiriatti M. GPT-3: Its nature, scope, limits, and consequences // Minds and Machines. 2020. vol. 30, no. 4, pp. 681–694. <https://doi.org/10.1007/s11023-020-09548-1>
  23. Achiam J., Adler S., Agarwal S. et al. Gpt-4 technical report. arXiv, 2023, arXiv:2303.08774. <https://doi.org/10.48550/arXiv.2303.08774>
  24. Bodimani M. Assessing the impact of transparent AI systems in enhancing user trust and privacy. Journal of Science & Technology, 2024, vol. 5, no. 1, pp. 50–67. <https://doi.org/10.55662/JST.2024.5102>
  25. Lu Z., Li Z., Chiang C.-W., Yin M. Strategic adversarial attacks in AI-assisted decision making to reduce human trust and reliance. Proc. of the Thirty-Second International Joint Conference on Artificial Intelligence, 2023, pp. 3020–3028. <https://doi.org/10.24963/ijcai.2023/337>
  26. He Y., Xiao L. Structured pruning for deep convolutional neural networks: A survey. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, vol. 46, no. 5, pp. 2900–2919. <https://doi.org/10.1109/tpami.2023.3334614>
  27. Ding S., Zhang L., Pan M., Yuan X. PATROL: Privacy-oriented pruning for collaborative inference against model inversion attacks. Proc. of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), 2024, pp. 4704–4713. <https://doi.org/10.1109/wacv57701.2024.00465>
  28. Fang G., Ma X., Song M., Mi M.B., Wang X. Depgraph: Towards any structural pruning. Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023, pp. 16091–16101. <https://doi.org/10.1109/cvpr52729.2023.01544>
  29. Wen L., Zhang X., Bai H., Xu Z. Structured pruning of recurrent neural networks through neuron selection. Neural Networks, 2020, vol. 123, pp. 134–141. <https://doi.org/10.1016/j.neunet.2019.11.018>
  30. Zhao M., Peng J., Yu S., Liu L., Wu N. Exploring structural sparsity in CNN via selective penalty. IEEE Transactions on Circuits and Systems for Video Technology, 2022, vol. 32, no. 3, pp. 1658–1666. <https://doi.org/10.1109/tcsvt.2021.3071532>
  31. Shen M., Molchanov P., Yin H., Alvarez J.M. When to prune? a policy towards early structural pruning. Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022, pp. 12237–12246. <https://doi.org/10.1109/cvpr52688.2022.01193>
  32. Katoch S., Chauhan S.S., Kumar V. A review on genetic algorithm: past, present, and future. Multimedia Tools and Applications, 2021, vol. 80, pp. 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>
  33. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv, 2014, arXiv:1409.1556. <https://doi.org/10.48550/arXiv.1409.1556>
  34. Zhou Y., Ren F., Nishide S., Kang X. Facial sentiment classification based on resnet-18 model. Proc. of the 2019 International Conference on Electronic Engineering and Informatics (EEI), 2019, pp. 463–466. <https://doi.org/10.1109/eei48997.2019.00106>
  35. Recht B., Roelofs R., Schmidt L., Shankar V. Do CIFAR-10 classifiers generalize to CIFAR-10? arXiv, 2018, arXiv:1806.00451. <https://doi.org/10.48550/arXiv.1806.00451>
  36. Liu Q., Mukhopadhyay S. Unsupervised learning using pretrained CNN and associative memory bank. Proc. of the International Joint Conference on Neural Networks (IJCNN), 2018, pp. 01–08. <https://doi.org/10.1109/ijcnn.2018.8489408>
  37. Jeevan P., Sethi A. Vision Xformers: Efficient attention for image classification. arXiv, 2021, arXiv:2107.02239. <https://doi.org/10.48550/arXiv.2107.02239>
  38. Hou Y., Wu Z., Cai X., Zhu T. The application of improved densenet algorithm in accurate image recognition. Scientific Reports, 2024, vol. 14, no. 1, pp. 8645. <https://doi.org/10.1038/s41598-024-58421-z>

## Авторы

**Кузьмин Владимир Никифорович** — доктор военных наук, профессор, ведущий научный сотрудник, Военно-космическая академия имени А.Ф.Можайского, Санкт-Петербург, 197198, Российской Федерации,  57220813706, <https://orcid.org/0000-0002-6411-4336>, [vka@mil.ru](mailto:vka@mil.ru)

## Authors

**Vladimir N. Kuzmin** — D.Sc. (Military Science), Professor, Leading Researcher, Mozhaisky Military Aerospace Academy, Saint Petersburg, 197198, Russian Federation,  57220813706, <https://orcid.org/0000-0002-6411-4336>, [vka@mil.ru](mailto:vka@mil.ru)

**Менисов Артем Бакытжанович** — кандидат технических наук, докторант, Военно-космическая академия имени А.Ф.Можайского, Санкт-Петербург, 197198, Российская Федерация, [sc 57220815185](#), <https://orcid.org/0000-0002-9955-2694>, [vka@mil.ru](mailto:vka@mil.ru)

**Сабиров Тимур Римович** — кандидат технических наук, старший преподаватель, Военно-космическая академия имени А.Ф.Можайского, Санкт-Петербург, 197198, Российская Федерация, [sc 55496404500](#), <https://orcid.org/0000-0002-6807-2954>, [vka@mil.ru](mailto:vka@mil.ru)

Статья поступила в редакцию 25.04.2024

Одобрена после рецензирования 17.07.2024

Принята к печати 16.09.2024

**Artem B. Menisov** — PhD, Doctoral Student, Mozhaisky Military Aerospace Academy, Saint Petersburg, 197198, Russian Federation, [sc 57220815185](#), <https://orcid.org/0000-0002-9955-2694>, [vka@mil.ru](mailto:vka@mil.ru)

**Timur R. Sabirov** — PhD, Senior Lecturer, Mozhaisky Military Aerospace Academy, Saint Petersburg, 197198, Russian Federation, [sc 55496404500](#), <https://orcid.org/0000-0002-6807-2954>, [vka@mil.ru](mailto:vka@mil.ru)

*Received 25.04.2024*

*Approved after reviewing 17.07.2024*

*Accepted 16.09.2024*



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-779-787

## ViSL model: The model automatically generates sentences of Vietnamese sign language

Khanh Dang<sup>1</sup>✉, Igor A. Bessmertny<sup>2</sup>

<sup>1,2</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>1</sup> [dangkhanhmta.2020@gmail.com](mailto:dangkhanhmta.2020@gmail.com)✉, <https://orcid.org/0009-0009-5882-7653>

<sup>2</sup> [bessmertny@itmo.ru](mailto:bessmertny@itmo.ru), <https://orcid.org/0000-0001-6711-6399>

### Abstract

The main problem in building intelligent systems is the lack of data for machine learning, which is especially important for sign language recognition for the deaf and hard of hearing. One of the ways to increase the amount of data for training is synthesis. Unlike speech synthesis, it is impossible to create a sequence of gestures in Vietnamese and some other languages that exactly repeat the text. This is due to the significant limitations of the gesture dictionary and the different word order in sentences. The aim of the work is to enrich the educational corpus of video data for use in creating recognition systems for the Vietnamese Sign Language (ViSL). Since it is impossible to translate the words of the source text into gestures one to one, the problem of translating from a regular language into a sign language arises. The paper proposes to use a two-phase process for this. The first phase involves pre-processing the text with standardization of the text format, segmentation of words and sentences, and then encoding the words using the sign language dictionary. At this stage, it should be noted that there is no need to remove punctuation marks and stop words, since they are related to the accuracy of the  $N$ -gram model. Next, instead of using syntactic analysis, a statistical method for forming a sequence of gestures is used, and the Markov model on the transition graph between words is taken as a basis in which the probability of the next word depends only on the two previous words. Transition probabilities are calculated on the existing marked corpus of the ViSL. The Breadth-first Search method is used to compile a list of all sentences generated based on a given grammatical rule and a matrix of semantic interactions between words. The inverse of the logarithm of the product of the probabilities of co-occurrence of consecutive 3-word phrases in a sentence is used to estimate the frequency of occurrence of that sentence in a given data set. Based on the ViSL data of 3,234 words, we calculated probability matrices representing the relationships between words based on Vietnamese natural language data with 50 million sentences collected from Vietnamese newspapers and magazines. For different grammar rules, we compare the number of generated sentences and evaluate the accuracy of the 50 most frequent sentences. The average accuracy is 88 %. The accuracy of the generated sentences is estimated by manual statistical methods. The number of generated sentences depends on the number of word parts that are labeled according to the grammar rules. The semantic accuracy of the generated sentences will be very high if the search words are labeled with the correct part-of-speech tagging. Compared with machine learning methods, our proposed method gives very good results for languages without inflections and word order that follow certain rules, such as Vietnamese, and does not require large computational resources. The disadvantage of this method is that its accuracy largely depends on the type of word, sentence, and word segmentation. The relationship of words depends on the observed dataset. Future research direction is to generate paragraphs in sign language. The obtained data can be used in machine learning models for sign language processing tasks.

### Keywords

Vietnamese sign language, sign language model, automatic sentence generation,  $n$ -gram, Markov model, breadth-first search, data enrichment, grammatical rules

**For citation:** Dang Kh., Bessmertny I.A. ViSL model: The model automatically generates sentences of Vietnamese sign language. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 779–787. doi: 10.17586/2226-1494-2024-24-5-779-787

УДК 004.932.72'1, 004.852

## ViSL model: модель автоматической генерации предложений вьетнамского языка жестов

Хань Данг<sup>1</sup>✉, Игорь Александрович Бессмертный<sup>2</sup>

<sup>1,2</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>1</sup> dangkhanhma.2020@gmail.com✉, <https://orcid.org/0009-0009-5882-7653>

<sup>2</sup> bessmertny@itmo.ru, <https://orcid.org/0000-0001-6711-6399>

### Аннотация

**Введение.** Основной проблемой при построении интеллектуальных систем является недостаточность данных для машинного обучения, что особенно актуально для распознавания языка жестов для глухих и слабослышащих людей. Одним из способов увеличения объема данных для обучения интеллектуальных систем является их синтез. В отличие от синтеза речи, создавать последовательность жестов на вьетнамском и некоторых других языках, в частности повторяющих текст, невозможно. Это связано с существенной ограниченностью словаря жестов и отличающимся порядком слов в предложениях. Целью работы является обогащение обучающего набора видеоданных для создания систем распознавания вьетнамского языка жестов (Vietnamese Sign Language, ViSL). **Метод.** Поскольку транслировать слова исходного текста в жесты невозможно, возникает задача перевода с обычного языка на жестовый. Для решения поставленной задачи в работе использован двухфазный процесс. На первой фазе выполняется предварительная обработка текста со стандартизацией текстового формата, сегментацией слов и предложений, а затем кодирование слов с помощью словаря языка жестов. На данном этапе не требуется удалять знаки препинания и стоп-слова, поскольку они связаны с точностью  $N$ -граммовой модели. На второй фазе вместо использования синтаксического анализа применяется статистический метод формирования последовательности жестов. При этом за основу берется марковская модель на графе переходов между словами, в которой вероятность следующего слова зависит только от двух предыдущих слов. Вероятности переходов вычисляются на существующем размеченном наборе ViSL. Метод графового поиска в ширину используется для составления списка всех предложений, сгенерированных на основе заданного грамматического правила и матрицы семантического взаимодействия между словами. Обратное значение логарифма произведения вероятности совместного появления последовательных словосочетаний из трех слов в предложении используется для оценки частоты встречаемости этого предложения в заданном наборе данных. **Основные результаты.** Основываясь на данных ViSL, состоящих из 3234 слов, рассчитаны матрицы вероятности, представляющие отношения между словами, на основе данных ViSL с 50 млн предложений, собранных из вьетнамских газет и журналов. Для различных грамматических правил выполнено сравнение количества сгенерированных предложений и оценка точности 50 наиболее часто встречающихся предложений. Средняя точность составила 88 %. Точность сгенерированных предложений оценена статистическими методами. Показано, что число сгенерированных предложений зависит от количества частей слова, которые помечены в соответствии с правилами грамматики. Семантическая точность сгенерированных предложений высока, если поисковые слова помечены правильными частями речи. **Обсуждение.** По сравнению с методами машинного обучения, предлагаемая модель дает хорошие результаты для языков без словоизменений и порядка слов, следующих определенным правилам, таких как вьетнамский язык, и не требует больших вычислительных ресурсов. Недостатком модели является зависимость точности от типа слова, предложения и сегментации слов. Взаимосвязь слов зависит от наблюдаемого набора данных. Будущее направление исследований — создание азбачев на языке жестов. Полученные данные могут быть использованы в моделях машинного обучения для задач обработки языка жестов.

### Ключевые слова

вьетнамский язык жестов, модель языка жестов, автоматическая генерация предложений,  $n$ -граммы, модель Маркова, метод графового поиска в ширину, обогащение данных, грамматические правила

**Ссылка для цитирования:** Данг Х., Бессмертный И.А. ViSL model: модель автоматической генерации предложений вьетнамского языка жестов // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 779–787 (на англ. яз.). doi: 10.17586/2226-1494-2024-24-5-779-787

### Introduction

Recent years have been marked by the rapid development of artificial intelligence technologies which have significantly changed the quality of human life, especially for people with disabilities. In particular, research in the field of sign language recognition at the word [1–3] and sentence level [4–6] has yielded very good results opening promising directions for further development aimed at reducing the socialization gap of people with hearing and speech impairments. Sign language in each country has its own unique characteristics, but the common point is that gestures and facial expressions are the

main elements of sign language. From a semantic point of view, sign language is closely related to natural language and carries national and cultural characteristics. To express the meaning of a sentence in sign language, it is necessary to perform a grammatical conversion process from natural language to sign language, and then match the words with the corresponding gestures. In the sign languages of some countries, such as Vietnam [7] and Russian [8], word order changes compared to natural languages. One of the problems of generating gestures is that the vocabulary of sign language is significantly smaller compared to the vocabulary of natural languages. In particular, Vietnamese Sign Language (ViSL) has only 3,234 words.

The task of recognizing sign language using machine learning requires large amounts of labeled data. A proven method for enriching data corpora is synthesis. The purpose of this study is to enrich labeled data corpora for ViSL recognition by generating sign language interpretation videos.

### Problems with language models

In the field of natural language processing, language models are widely and effectively used in tasks such as: language recognition and machine translation models [9], spelling error detection and sentence editing [10], etc. Building a language model is necessary to create applications that require understanding language. Sign languages are closely related to natural languages, but using natural language models to understand sign languages is not possible. The reason is that word order and grammatical structure are different; many words in natural languages were not represented in sign language [7, 8].

Published research on sign language processing mainly focuses on problems and methods of recognizing sign language at the letter and word level [1–3], at the continuous level [4–6]. To advance research at higher and more complex levels, such as problems in machine translation from sign language, it is necessary to create a language model specifically for sign language. An effective model of sign language will help the computer take into account the semantics and representational context of sentences.

The construction of a natural language model can be carried out in accordance with three main approaches.

- Construction of a language model using a knowledge base created by language experts [11]. The language model is built on the basis of a set of knowledge base rules: Grammatical — Ungrammatical, Intra-grammatical — Extra-grammatical, Non-grammatical — Out-of-grammatical, Qualitative language model — Quantitative language model. The advantage of this method is that it does not require training data. The disadvantage is that it is difficult to develop and requires time and the involvement of language experts. This model produces highly accurate results for written language (formal), but the results may not be reliable for spoken language (informal). In addition, it is unable to predict the appearance of a word and is unable to generate text.
- Building language models using statistical methods [12]. This is a method for calculating the probability distribution for a string of words of length  $k$  words:  $w_1, \dots, w_K$  denoted by  $P(w_1, w_2, \dots, w_K)$ , where  $\{w_1, w_2, \dots, w_K\} \in W$  is a set of data belonging to a particular language. Then the probability of occurrence of the sequence  $w_1, w_2, \dots, w_K$  will be calculated using the following formula:

$$\begin{aligned} P(w_1, w_2, \dots, w_K) &= \\ &= P(w_1)P(w_2|w_1) \dots P(w_K|w_1, w_2, \dots, w_{K-1}) = \\ &= \prod_{k=1}^K P(w_k|w_1, w_2, \dots, w_{k-1}), \end{aligned}$$

where  $P(w_K|w_1, w_2, \dots, w_{K-1})$  this is the probability of the word  $w_K$  given the known probability of occurrence of the sequence  $w_1, w_2, \dots, w_{K-1}$ . Given that the frequency of occurrence of the strings  $w_1, w_2, \dots, w_{K-1}$  and  $w_1, w_2, \dots, w_K$  is equal to  $f_{K-1}$  and  $f_K$ , respectively, we can calculate the probability of occurrence of the word  $w_K$  in a set of texts when we know that the probability of occurrence of the string  $w_1, w_2, \dots, w_{K-1}$  is equal to:  $P(w_K|w_1, w_2, \dots, w_{K-1}) = \frac{f_K}{f_{K-1}}$ . Calculating the probability of occurrence of the word  $w_K$ , taking into account that it depends only on the occurrence of  $N - 1$  words before it in accordance with Markov's law, we obtain the formula for the  $N$ -gram Markov model [13]:

$$P(w_K|w_1, w_2, \dots, w_{K-1}) = P(w_K|w_{K-N+1}, w_{K-N+2}, \dots, w_{K-1}).$$

The disadvantage of this method is that it requires large computational and storage resources for large data sets. In addition, if a pair of words rarely occurs together in this data set, the probability will be close to 0. To overcome this disadvantage, data smoothing methods are used in  $N$ -gram calculations, such as Discounting, Back-off, and Interpolation. In addition to improving the accuracy of semantic structure, some studies have combined  $N$ -grams with a structured Language Model (Structured LM).

#### — Building language models using a neural network.

For this method, the words in a sentence will be encoded into vectors, and the sentences will be a series of encoded vectors of words. According to this architecture, the input data will be fed to neural networks for processing time series data, such as Recurrent Neural Networks (RNN) [13], Long Short-Term Memory (LSTM) [14], Transform [15]. The main advantage of this method is that it allows you to perceive the context of words, producing accurate results without paying attention to the grammar of the language. The disadvantage is the need for large amounts of data and large computing resources.

In addition to the above approaches, the Large Language Model (LLM) [16] is currently attracting the most attention due to its accuracy and ability to understand language. However, implementing the LLM model is very difficult because it is very expensive in terms of computational resources as well as a huge amount of data. For sign languages, the vocabulary size is not large enough for us to build a model to obtain sign language data using statistical methods.

### Description of the proposed model

#### Automatic generation of sentences in sign language

To build a model of machine translation into sign language, the task of recognizing gestures in videos is not enough. A sign language machine translation model is effective if it is implemented in conjunction with a language model for a specific sign language, since the vocabulary of sign languages is often much smaller. Thus, building a language model for sign language using statistical methods would be appropriate. In this study, the main tasks for

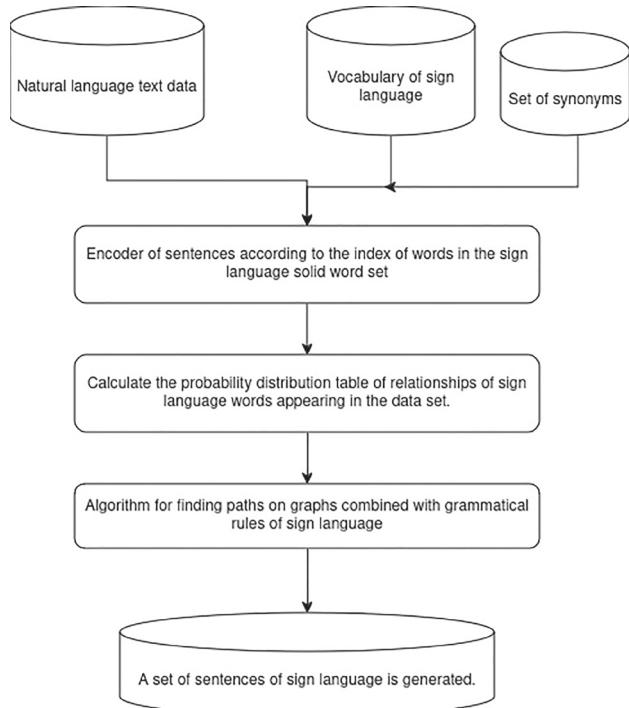


Fig. 1. Diagram summarizing the process of generating sentences in sign language

constructing a language model of ViSL and generating Sign Language sentences are summarized as shown in Fig. 1.

After performing pre-processing steps on the input text dataset, such as removing special characters, html tags, word segmentation, punctuation standardization, sentence segmentation, the sentences in the dataset will be encoded and indexed by words in the ViSL dictionary. A dataset of synonyms will be added to reduce variance given that the number of words in sign language is much less than in natural language. Words that are not in the sign language dictionary will be coded as 0.

We will calculate the probability distribution table of interactions between words in a sign language dictionary according to the Markov property of the  $N$ -gram model. Next, algorithms that map paths in a graph in combination with the grammatical rules of sign language will be used to generate sentences in sign language.

#### Constructing a probability matrix representing the interactions between words in the ViSL dictionary

ViSL sentences are a set of sign language words of size  $L$  words, with any two words from the dictionary set  $\{W_i, W_j\} \in VS$ ,  $0 \leq i, j \leq N - 1$ . Then  $P(W_{ij}, d)$  is the probability that the word  $W_j$  will appear after the word  $W_i$  at a distance of  $d$  words, will be calculated by the formula:

$$\{P(W_{ij}, d) = \frac{f_{(W_i|W_j,d)}}{f_{W_j}} \text{index}(j) - \text{index}(i) = d, d > 0,$$

where  $f_{(W_i|W_j)}$  frequency of occurrence of the word  $W_i$  and the word  $W_j$  in one sentence and in the data set. Condition:  $\text{index}(j) - \text{index}(i) = d, d > 0$  guarantees that the word  $W_j$  follows the word  $W_i$  at a distance of  $d$  words,  $f_{W_j}$  is the frequency of occurrence of the word  $W_j$  in the data set.

The above formula corresponds to the properties of the Markov model, that is, we assume that the occurrence of the word  $W_j$  depends only on the previous  $n$  words. In this study, we consider the occurrence of the word  $W_j$  depending only on the word  $W_i$ . The  $d$  value reflects the interaction between two words. The smaller  $d$ , the more the word  $W_j$  will depend on the word  $W_i$ . We calculate three probability distribution tables corresponding to the values  $d = 1, 2, 3$ .

To optimize time, it is necessary to calculate a table of probability distributions for matching words in a data set. We propose a method for encoding a dataset and then reviewing each sentence. A data set of size  $N$  sentences will have  $O(N)$  complexity.

#### BFS search algorithm for generating sentences in ViSL

Unlike natural language, the word order of sentences in ViSL varies compared to natural language [17]. In natural languages, the sentence structure is usually  $S(\text{subject}) — V(\text{predicate}) — O(\text{object})$ , while in sign languages the sentence order will be:  $S(\text{subject}) — O(\text{object object}) — V(\text{predicate})$ . This means that the object must first be identified before the appropriate gestures can be used to express the action. Here are some basic grammatical rules for constructing sentences in ViSL — Subject — Object — Predicate — Words of time; Adverb — Subject — Predicate and Object — Adverb.

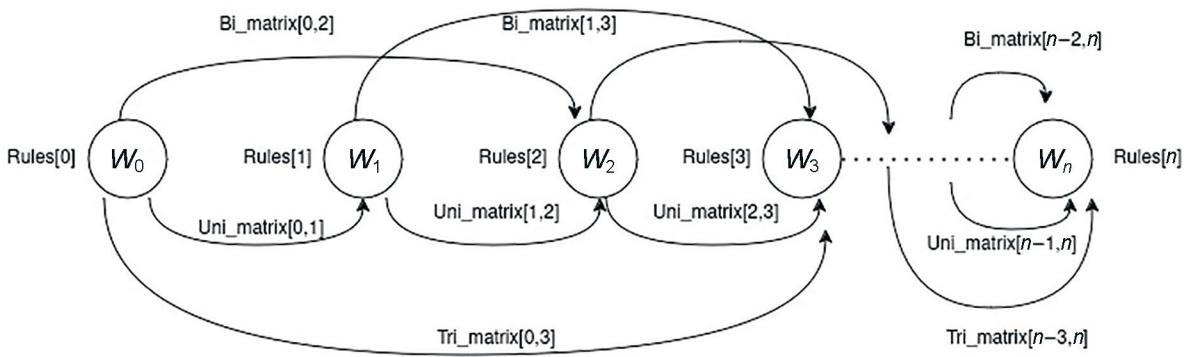
The index of each word in a set of sign language words represents a vertex in the graph. The probability distribution table of the word occurrence ratio in a data set is considered as an adjacency matrix with the probability values as the weights of the directed graph. An example of the BFS algorithm on a graph used in combination with grammar rules and a Markov model to generate sign language sentences is shown in Fig. 2.

When calculating three matrices representing the relations of interaction of words in a dataset, if the distance between them is calculated for each  $d$  equal to 1, 2, 3, we get the corresponding matrices: **uniMatrix**, **biMatrix**, **triMatrix**. Given the **Rules** grammatical rule, a sign language sentence  $S = \{w_0, w_1, \dots, w_n\}$  is generated, which must meet the following conditions:

$$\begin{aligned} &\{ \text{uniMatrix}[i, i + 1]! = 0, \forall i : 0 \leq i < \text{len}(\text{Rules}) - \\ &- 1 \text{ biMatrix}[i, i + 2]! = 0, \forall i : 0 \leq i < \text{len}(\text{Rules}) - \\ &- 2 \text{ triMatrix}[i, i + 3]! = 0, \forall i : 0 \leq i < \text{len}(\text{Rules}) - \\ &- 3 \text{ mapIndex}[i]! = \text{Rules}[i], \forall i : 0 \leq i < \text{len}(\text{Rules}), \end{aligned}$$

where, **mapIndex** is the coding map index of words corresponding to the marking of parts of speech. Then the probability of generating a sign language sentence of length  $n$  words is calculated by the formula of simultaneous probability of  $N$ -gram clusters as:

$$\begin{aligned} \text{Probability of sentence occurrence} - PS = & \prod_{i=0}^{n-1} M[i, i + 1]. \\ & \prod_{i=0}^{n-2} M[i, i + 2]. \prod_{i=0}^{n-3} M[i, i + 3]. \end{aligned}$$



\$W\_0, W\_1, \dots, W\_n\$ are words in the sign language dictionary, used to generate sentences.

Rules is an array representing a Vietnamese grammar rule.

Uni\_matrix, Bi\_matrix, Tri\_matrix are matrices representing the interactions between words of the sign language dictionary, calculated based on the distance value from \$d\$ equal to 1, 2, 3 respectively.

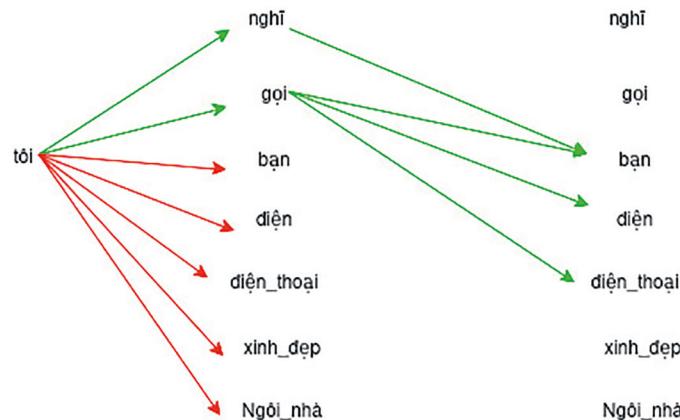
**Example:** Rules = [N, V, N]

map\_index = {1:N; 2:V; 3:V; 4:N; 5:N; 6:N; 7:A; 8:N}

Word set: VS = {tôi, nghī, gọi, bạn, điện, ngôi\_nhà, xinh\_dep, điện\_thoại}

Uni\_matrix [1,2] != 0    Uni\_matrix [1,3] != 0    Bi\_matrix [1,4] != 0    Bi\_matrix [1,8] != 0    Bi\_matrix [1,5] != 0

Uni\_matrix [2,4] != 0    Uni\_matrix [3,4] != 0    Uni\_matrix [3,5] != 0    Uni\_matrix [3,8] != 0



Results:

sentence\_1 = [tôi, nghī, bạn]

sentence\_2 = [tôi, gọi, bạn]

sentence\_3 = [tôi, gọi, điện]

sentence\_4 = [tôi, gọi, điện\_thoại]

Fig. 2. Representation of a sentence in sign language generated in accordance with a grammatical rule and calculated with probability according to the Markov rule

For very large data sets, the frequency of words can be much higher than the frequency of phrases. To avoid losses in the calculation, we transform the logarithms, the results are as follows:

$$\text{Cost} = (-1) \times \log(PS) = (-1) \times \left( \sum_{i=0}^{n-1} \log(M[i, i+1]) + \sum_{i=0}^{n-2} \log(M[i, i+2]) + \sum_{i=0}^{n-3} \log(M[i, i+3]) \right).$$

\$M[i, i+1]\$ refers to the probability of the word \$S[i]\$ appearing before the word \$S[i+1]\$ in the dataset. When 2 consecutive words correspond to the value \$d = 1\$, we use **uniMatrix** to calculate. When \$d = 2\$, we consider \$S[i]\$ and \$S[i+2]\$, then **biMatrix** is used for calculation. Similarly with \$M[i, i+3]\$, **triMatrix** is used for calculation.

Our goal is to find a set of words that correspond to the given grammatical rules and at the same time satisfy the probability condition. According to the Cost formula, the lower the Cost value, the higher the probability that the generated application is more likely to be encountered in the dataset.

We call the value Cost, because it has the same value as the cost in the task of finding the shortest path on the graph.

Graph path finding algorithms [17], such as Breadth-First Search (BFS) and Depth-First Search (DFS), are used to list all collocations according to a given grammatical rule. The BFS function for generating sign language sentences that satisfy the grammar rules and Markov states is configured as follows:

```

def BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, path, node,
rules):
    paths = []
    visited[node] = True
    new_path = path + [node]
    if len(new_path) == len(rules):
        Cost = calculate_Cost(new_path, uni_matrix, bi_matrix, tri_matrix)
        paths.append((new_path, Cost))
    else:
        for x in range(len(uni_matrix[node])):
            if len(new_path) == 1:
                if map_index[x] == list_rules[len(new_path)] and visited[x] == False:
                    if uni_matrix[node][x] != 0:
                        paths.extend(BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, new_
path, x, rules))
            if len(new_path) == 2:
                if map_index[x] == list_rules[len(new_path)] and visited[x] == False:
                    if uni_matrix[node][x] != 0 and bi_matrix[new_path[-2]][x] != 0:
                        paths.extend(BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, new_
path, x, rules))
            if len(new_path) > 2:
                if map_index[x] == list_rules[len(new_path)] and visited[x] == False:
                    if uni_matrix[node][x] != 0 and bi_matrix[new_path[-2]][x] != 0 and tri_
matrix[new_path[-3]][x] != 0:
                        paths.extend(BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, new_
path, x, rules))
    visited[node] = False
    paths.sort(key=lambda x: x[1], reverse=True)
    return paths

def BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, path, node,
rules):
    paths = []
    visited[node] = True
    new_path = path + [node]
    if len(new_path) == len(rules):
        Cost = calculate_Cost(new_path, uni_matrix, bi_matrix, tri_matrix)
        paths.append((new_path, Cost))
    else:
        for x in range(len(uni_matrix[node])):
            if len(new_path) == 1:
                if map_index[x] == list_rules[len(new_path)] and visited[x] == False:
                    if uni_matrix[node][x] != 0:
                        paths.extend(BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, new_
path, x, rules))
            if len(new_path) == 2:
                if map_index[x] == list_rules[len(new_path)] and visited[x] == False:
                    if uni_matrix[node][x] != 0 and bi_matrix[new_path[-2]][x] != 0:
                        paths.extend(BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, new_
path, x, rules))
            if len(new_path) > 2:
                if map_index[x] == list_rules[len(new_path)] and visited[x] == False:
                    if uni_matrix[node][x] != 0 and bi_matrix[new_path[-2]][x] != 0 and tri_
matrix[new_path[-3]][x] != 0:
                        paths.extend(BFS(map_index, uni_matrix, bi_matrix, tri_matrix, visited, new_
path, x, rules))
    visited[node] = False
    paths.sort(key=lambda x: x[1], reverse=True)
    return paths

```

## Experiments and results

The Vietnamese text dataset is collected from articles with a total number of sentences after preprocessing: 50 million sentences<sup>1</sup>.

After removing duplicate words, the ViSL dictionary has a size of 3,234 words<sup>2</sup>.

We calculate the probability distribution table of interactions between words in sign language according to the distance value  $d = 1, 2, 3$  words. The probability distribution tables of interactions between words are saved as a numpy file, the word encoding table and its index are saved as a text file.

When specifying the word “tôi – I” as the initial vertex with the grammatical rule: “ $N$  (noun) –  $V$  (verb) –  $N$  (noun)”. We have generated 44,290 offers. Of these, the 10 most common sentences are shown in Table 1.

To compare the accuracy of three models with different  $d$  values, we generated 5 data samples for each model. Each data sample contains the 20 sentences with the highest probability of occurrence generated from the seed word and the grammar rule. When calculating the semantic accuracy of data samples, we get the following comparison Table 2.

The source code of the project can be viewed at the link<sup>3</sup>.

## Conclusion and discussion

In this study, we built a model to generate ViSL sentences. The advantage of this model is that it is very accurate and does not require large computational resources. We propose a method to construct a matrix representing the semantic interactions between words in the ViSL dictionary, and then apply grammar rules and breadth search algorithms to generate ViSL. The disadvantage of this method is that its accuracy depends on the accuracy of the data processing steps, such as part-word labeling, sentence segmentation, and Vietnamese word segmentation. Our model can be used to generate sign language sentences by estimating the probability of the next word in a sentence, but this probability is calculated based on the collected dataset. The next direction of research is to build a model to generate paragraphs in sign language. The findings can be applied to machine learning and neural models to solve more complex sign language processing problems.

Table 1. Example of generating sentences of sign language

Sign language sentences	Translate	Cost
tôi → nghĩ → bạn	I think you	16.450
tôi → gọi → điện	I call	16.644
tôi → nghĩ → chị	I think you	16.974
tôi → muốn → bạn	I want you	17.527
tôi → gọi → điện_thoại	I call	18.172
tôi → nghe → báo_cáo	I heard the report	18.336
tôi → nhận → trách_nhiệm	I take responsibility	18.383
tôi → nghe → chị	I hear you	18.488
tôi → hỏi → bạn	I ask you	18.523

Table 2. Comparison of the performance of language models with different grammar rules

Rules	Total number of sentences generated	Accuracy, %
$N - V - N$	4,636,156	94
$P - V - N - E - Np$	3,074,695	80
$N - V - M - N$	42,608,705	90
$N - V - A$	1,251,234	96
$P - V - A$	46,122	84
$P - V - N$	164,927	82
$P - V - Nc - N$	46,323	96
$E - N - V - Nc - A$	1,171,297	70
$Np - V - Nc - N$	51,276	92
$P - V - M - N$	1,474,344	96
Average value of the sum		88

*Footnote:*  $N$  — Noun,  $V$  — Verb,  $A$  — Adjective,  $P$  — Pronoun,  $Np$  — Proper Noun,  $Nc$  — Classification,  $E$  — Sentence,  $M$  — Numeral.

## Conclusion and discussion

In this study, we built a model to generate Vietnamese Sign Language (ViSL) sentences. The advantage of this model is that it is very accurate and does not require large computational resources. We propose a method to construct a matrix representing the semantic interactions between words in the ViSL dictionary, and then apply grammar rules and breadth search algorithms to generate ViSLe. The disadvantage of this method is that its accuracy depends on the accuracy of the data processing steps, such as part-word labeling, sentence segmentation, and Vietnamese word segmentation. Our model can be used to generate sign language sentences by estimating the probability of the next word in a sentence, but this probability is calculated based on the collected dataset. The next direction of research is to build a model to generate paragraphs in sign language. The findings can be applied to machine learning and neural models to solve more complex sign language processing problems.

<sup>1</sup> Available at: <https://drive.google.com/file/d/1GFbeqs6HmCYs0JwJgivOy2Bvb06M8OI/view> (date accessed: 14.04.2024).

<sup>2</sup> Available at: <https://github.com/DangKhanhITMO/VnSignLanguage> (date accessed: 14.04.2024).

<sup>3</sup> Available at: [https://colab.research.google.com/drive/1-8\\_vp24tKNchhb4s3Q1WknxU46XsOg1O?usp=sharing](https://colab.research.google.com/drive/1-8_vp24tKNchhb4s3Q1WknxU46XsOg1O?usp=sharing) (date accessed: 14.06.2024).

## References

1. Katti R.K., Sujatha C., Desai P., Shankar G. Character and word level gesture recognition of indian sign language. *Proc. of the 2023 IEEE 8<sup>th</sup> International Conference for Convergence in Technology (I2CT)*, 2023, pp. 1–6. <https://doi.org/10.1109/I2CT57861.2023.10126314>
2. Naz N., Sajid H., Ali S., Hasan O., Ehsan M.K. Signgraph: An efficient and accurate pose-based graph convolution approach toward sign language recognition. *IEEE Access*, 2023, vol. 11, pp. 19135–19147. <https://doi.org/10.1109/ACCESS.2023.3247761>
3. Boháček M., Hruž M. Sign pose-based transformer for word-level sign language recognition. *Proc. of the 2022 IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW)*, 2022, pp. 182–191. <https://doi.org/10.1109/WACVW54805.2022.00024>
4. Jiang Y., Li F., Li Z., Liu Z., Wang Z. Enhancing continuous sign language recognition with Self-Attention and MediaPipe Holistic. *Proc. of the 2023 8<sup>th</sup> International Conference on Instrumentation, Control, and Automation (ICA)*, 2023, pp. 97–102. <https://doi.org/10.1109/ICA58538.2023.10273118>
5. Nayan N., Ghosh D., Pradhan P.M. An unsupervised learning approach to handle movement epenthesis in continuous sign language recognition. *Proc. of the 2022 17<sup>th</sup> International Conference on Control, Automation, Robotics and Vision (ICARCV)*, 2022, pp. 862–867. <https://doi.org/10.1109/ICARCV57592.2022>
6. Tran K.B., Nguyen U.D., Huynh Q.T. Continuous sign language recognition using MediaPipe. *Proc. of the 2023 International Conference on Advanced Technologies for Communications (ATC)*, 2023, pp. 493–498. <https://doi.org/10.1109/ATC58710.2023.10318855>
7. Quach L.-D., Nguyen C.-N. Conversion of the Vietnamese grammar into sign language structure using the example-based machine translation algorithm. *Proc. of the 2018 International Conference on Advanced Technologies for Communications (ATC)*, 2018, pp. 27–31. <https://doi.org/10.1109/ATC.2018.8587584>
8. Kagirov I., Ryumin D., Ivanko D., Axyonov A., Karpov A. Russian sign language: History, grammar and sociolinguistic situation in brief. *Proc. of the Language Technologies for All (LT4All)*, 2019, pp. 71–74.
9. Singh C., Bansal R.K., Bansal S. Machine translation techniques using AI: A review. *Proc. of the 2023 IEEE International Conference on Computer Vision and Machine Intelligence (CVMI)*, 2023, pp. 1–5. <https://doi.org/10.1109/CVMI59935.2023.10464455>
10. Tan M., Chen D., Li Z., Wang P. Spelling error correction with BERT based on character-phonetic. *Proc. of the 2020 IEEE 6<sup>th</sup> International Conference on Computer and Communications (ICCC)*, 2020, pp. 1146–1150. <https://doi.org/10.1109/ICCC51575.2020.9345276>
11. Huang C., Feng Y., Zhang Y., Zhang W. Knowledge Base System of Electrical equipment management and potential risk control based on natural language processing technology. *Proc. of the 2023 Asia-Europe Conference on Electronics, Data Processing and Informatics (ACEDPI)*, 2023, pp. 439–445. <https://doi.org/10.1109/ACEDPI58926.2023.00090>
12. Liu S., Tang R., Chai J. A news automatic tagging method based on statistical language model. *Proc. of the 2017 10<sup>th</sup> International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, 2017, pp. 1–5. <https://doi.org/10.1109/CISP-BMEI.2017.8302092>
13. Xiao J., Zhou Z. Research Progress of RNN Language Model. *Proc. of the 2020 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*, 2020, pp. 1285–1288. <https://doi.org/10.1109/ICAICA50127.2020.9182390>
14. Ganai F., Khursheed F. Predicting next Word using RNN and LSTM cells: Stastical Language Modeling. *Proc. of the 2019 Fifth International Conference on Image Information Processing (ICIIP)*, 2019, pp. 469–474. <https://doi.org/10.1109/ICIIP47207.2019.8985885>
15. Acheampong F.A., Nunoo-Mensah H., Chen W. Recognizing emotions from texts using an ensemble of transformer-based language models. *Proc. of the 2021 18<sup>th</sup> International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP)*, 2021, pp. 161–164. <https://doi.org/10.1109/ICCWAMTIP53232.2021.9674102>
16. Lee H., Kim J.-H., Hwang E.J., Kim J., Park J.C. Leveraging large language models with vocabulary sharing for sign language translation. *Proc. of the 2023 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops (ICASSPW)*, 2023, pp. 1–5. <https://doi.org/10.1109/ICASSPW59220.2023.10193533>

## Литература

1. Katti R.K., Sujatha C., Desai P., Shankar G. Character and word level gesture recognition of indian sign language // Proc. of the 2023 IEEE 8<sup>th</sup> International Conference for Convergence in Technology (I2CT). 2023. P. 1–6. <https://doi.org/10.1109/I2CT57861.2023.10126314>
2. Naz N., Sajid H., Ali S., Hasan O., Ehsan M.K. Signgraph: An efficient and accurate pose-based graph convolution approach toward sign language recognition // IEEE Access. 2023. V. 11. P. 19135–19147. <https://doi.org/10.1109/ACCESS.2023.3247761>
3. Boháček M., Hruž M. Sign pose-based transformer for word-level sign language recognition // Proc. of the 2022 IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW). 2022. P. 182–191. <https://doi.org/10.1109/WACVW54805.2022.00024>
4. Jiang Y., Li F., Li Z., Liu Z., Wang Z. Enhancing continuous sign language recognition with Self-Attention and MediaPipe Holistic // Proc. of the 2023 8<sup>th</sup> International Conference on Instrumentation, Control, and Automation (ICA). 2023. P. 97–102. <https://doi.org/10.1109/ICA58538.2023.10273118>
5. Nayan N., Ghosh D., Pradhan P.M. An unsupervised learning approach to handle movement epenthesis in continuous sign language recognition // Proc. of the 2022 17<sup>th</sup> International Conference on Control, Automation, Robotics and Vision (ICARCV). 2022. P. 862–867. <https://doi.org/10.1109/ICARCV57592.2022.10004317>
6. Tran K.B., Nguyen U.D., Huynh Q.T. Continuous sign language recognition using MediaPipe // Proc. of the 2023 International Conference on Advanced Technologies for Communications (ATC). 2023. P. 493–498. <https://doi.org/10.1109/ATC58710.2023.10318855>
7. Quach L.-D., Nguyen C.-N. Conversion of the Vietnamese grammar into sign language structure using the example-based machine translation algorithm // Proc. of the 2018 International Conference on Advanced Technologies for Communications (ATC). 2018. P. 27–31. <https://doi.org/10.1109/ATC.2018.8587584>
8. Kagirov I., Ryumin D., Ivanko D., Axyonov A., Karpov A. Russian sign language: History, grammar and sociolinguistic situation in brief // Proc. of the Language Technologies for All (LT4All). 2019. P. 71–74.
9. Singh C., Bansal R.K., Bansal S. Machine translation techniques using AI: A review // Proc. of the 2023 IEEE International Conference on Computer Vision and Machine Intelligence (CVMI). 2023. P. 1–5. <https://doi.org/10.1109/CVMI59935.2023.10464455>
10. Tan M., Chen D., Li Z., Wang P. Spelling error correction with BERT based on character-phonetic // Proc. of the 2020 IEEE 6<sup>th</sup> International Conference on Computer and Communications (ICCC). 2020. P. 1146–1150. <https://doi.org/10.1109/ICCC51575.2020.9345276>
11. Huang C., Feng Y., Zhang Y., Zhang W. Knowledge Base System of Electrical equipment management and potential risk control based on natural language processing technology // Proc. of the 2023 Asia-Europe Conference on Electronics, Data Processing and Informatics (ACEDPI). 2023. P. 439–445. <https://doi.org/10.1109/ACEDPI58926.2023.00090>
12. Liu S., Tang R., Chai J. A news automatic tagging method based on statistical language model // Proc. of the 2017 10<sup>th</sup> International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). 2017. P. 1–5. <https://doi.org/10.1109/CISP-BMEI.2017.8302092>
13. Xiao J., Zhou Z. Research Progress of RNN Language Model // Proc. of the 2020 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA). 2020. P. 1285–1288. <https://doi.org/10.1109/ICAICA50127.2020.9182390>
14. Ganai F., Khursheed F. Predicting next Word using RNN and LSTM cells: Stastical Language Modeling // Proc. of the 2019 Fifth International Conference on Image Information Processing (ICIIP). 2019. P. 469–474. <https://doi.org/10.1109/ICIIP47207.2019.8985885>
15. Acheampong F.A., Nunoo-Mensah H., Chen W. Recognizing emotions from texts using an ensemble of transformer-based language models // Proc. of the 2021 18<sup>th</sup> International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP). 2021. P. 161–164. <https://doi.org/10.1109/ICCWAMTIP53232.2021.9674102>
16. Lee H., Kim J.-H., Hwang E.J., Kim J., Park J.C. Leveraging large language models with vocabulary sharing for sign language translation // Proc. of the 2023 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops (ICASSPW). 2023. P. 1–5. <https://doi.org/10.1109/ICASSPW59220.2023.10193533>

17. Garg H., Gupta I., Kumar K., Kaur B., Pundir D. Artificial intelligence based dynamic approach to visualize the graphs. *Proc. of the 2023 International Conference on Computational Intelligence, Communication Technology and Networking (CICTN)*, 2023, pp. 663–667. <https://doi.org/10.1109/CICTN57981.2023.10140873>
17. Garg H., Gupta I., Kumar K., Kaur B., Pundir D. Artificial intelligence based dynamic approach to visualize the graphs // Proc. of the 2023 International Conference on Computational Intelligence, Communication Technology and Networking (CICTN). 2023. P. 663–667. <https://doi.org/10.1109/CICTN57981.2023.10140873>

### Authors

**Khánh Dang** — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 59166515900](https://orcid.org/0009-0009-5882-7653), <https://orcid.org/0009-0009-5882-7653>, dangkhanhmta.2020@gmail.com

**Igor A. Bessmertny** — D.Sc., Full Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 36661767800](https://orcid.org/0000-0001-6711-6399), <https://orcid.org/0000-0001-6711-6399>, bessmertny@itmo.ru

### Авторы

**Данг Хань** — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 59166515900](https://orcid.org/0009-0009-5882-7653), <https://orcid.org/0009-0009-5882-7653>, dangkhanhmta.2020@gmail.com

**Бессмертный Игорь Александрович** — доктор технических наук, профессор, профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 36661767800](https://orcid.org/0000-0001-6711-6399), <https://orcid.org/0000-0001-6711-6399>, bessmertny@itmo.ru

Received 16.04.2024

Approved after reviewing 17.07.2024

Accepted 16.09.2024

Статья поступила в редакцию 16.04.2024

Одобрена после рецензирования 17.07.2024

Принята к печати 16.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-788-796

## Enhanced anomaly detection in network security: a comprehensive ensemble approach

Rashmikiran Pandey<sup>1</sup>✉, Mrinal Pandey<sup>2</sup>, Alexey N. Nazarov<sup>3</sup>

<sup>1,2</sup> Moscow Institute of Physics and Technology (National Research University), Moscow region, Dolgoprudny, 141701, Russian Federation

<sup>3</sup> Federal Research Center “Computer Science and Control” of the Russian Academy of Sciences, Moscow, 119333, Russian Federation

<sup>1</sup> rashmikiran@phystech.edu✉, <https://orcid.org/0000-0003-0042-6565>

<sup>2</sup> mrinalpandei@phystech.edu, <https://orcid.org/0009-0009-5151-6908>

<sup>3</sup> a.nazarov06@bk.ru, <https://orcid.org/0000-0002-0497-0296>

### Abstract

Detection and handling of anomalous behavior in the network systems are peremptory efforts to ensure security for vulnerable infrastructures amidst the dynamic context of cybersecurity. In this paper, we propose an ensemble machine learning model architecture that leverages the strengths of XGBoost, Gradient Boosting, Random Forest, and Support Vector Machine models to identify anomalies in the dataset. This method utilizes an ensemble of these models with weighted voting based on accuracy to enhance anomaly detection for robust and adaptive real-world network security. The proposed ensemble learning model is evaluated on standard metrics and demonstrates exceptional efficacy, achieving an impressive accuracy of 99.68 % on NSL KDD dataset. This remarkable performance extends the model prowess in discerning anomalies within network traffic showcasing its potential as a robust tool for enhancing cybersecurity measures against evolving threats.

### Keywords

anomaly detection, bagging and boosting, ensemble approach, network security, neural network

**For citation:** Pandey R., Pandey M., Nazarov A.N. Enhanced anomaly detection in network security: a comprehensive ensemble approach. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 788–796. doi: 10.17586/2226-1494-2024-24-5-788-796

УДК 004.89

## Расширенное обнаружение аномалий в сетевой безопасности: комплексный ансамблевый подход

Рашмикиран Пандей<sup>1</sup>✉, Мринал Пандей<sup>2</sup>, Алексей Николаевич Назаров<sup>3</sup>

<sup>1,2</sup> Московский физико-технический институт (национальный исследовательский университет), Московская область, Долгопрудный, 141701, Российская Федерация

<sup>3</sup> Федеральный исследовательский центр «Информатика и управление» Российской академии наук», Москва, 119333, Российская Федерация

<sup>1</sup> rashmikiran@phystech.edu✉, <https://orcid.org/0000-0003-0042-6565>

<sup>2</sup> mrinalpandei@phystech.edu, <https://orcid.org/0009-0009-5151-6908>

<sup>3</sup> a.nazarov06@bk.ru, <https://orcid.org/0000-0002-0497-0296>

### Аннотация

Обнаружение и устранение аномального поведения сетевых систем являются важнейшими мерами по обеспечению безопасности уязвимых инфраструктур в динамичном контексте кибербезопасности. Предложена архитектура модели машинного обучения ensemble, которая использует преимущества моделей XGBoost, Gradient Boosting, случайного леса и метода опорных векторов для выявления аномалий в наборе данных. Представленный подход использует совокупность перечисленных моделей с взвешенным голосованием и основан на точности, для улучшения обнаружения аномалий и обеспечения надежной и адаптивной сетевой безопасности в реальном времени. Модель коллективного обучения оценивается по стандартным показателям

© Pandey R., Pandey M., Nazarov A.N., 2024

и демонстрирует исключительную эффективность, достигая высокой точности 99,68 % в наборе данных NSL KDD. Высокая производительность подхода расширяет возможности модели в выявлении аномалий в сетевом трафике, демонстрирует ее потенциал в качестве надежного инструмента для усиления мер кибербезопасности против развивающихся угроз.

#### Ключевые слова

обнаружение аномалий, пакетирование и бустинг, групповой подход, сетевая безопасность, нейронная сеть

**Ссылка для цитирования:** Пандей Р., Пандей М., Назаров А.Н. Расширенное обнаружение аномалий в сетевой безопасности: комплексный ансамблевый подход // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 788–796 (на англ. яз.). doi: 10.17586/2226-1494-2024-24-5-788-796

## Introduction

In the ever-evolving cyber landscape, cybersecurity systems face a formidable challenge in safeguarding networked environments from anomalous activities. These threats, ranging from sophisticated intrusions to stealthy attacks, pose unprecedented threats to the confidentiality, integrity, and availability of sensitive information [1]. While conventional signature-based intrusion detection systems are effective in identifying known malicious threats, they often fall short in detecting novel and previously unseen anomalies. This highlights the urgent need for advanced anomaly detection techniques that can adapt to the ever-changing nature of cyber threats [2].

Existing work have intensely analyzed the applicability of single-classifier machine learning models for anomaly detection. However, failure of the standalone machine learning models to effectively address the complexities of network security has fuelled further investigation in this domain. The network security domain encapsulates a unique sort of challenges like imbalanced datasets evolving methodologies of attack and the requisite for real-time detection [3]. The development of novel methods capable of identifying anomalous patterns in huge network datasets is a requirement that arises from the ever-growing sophistication and diversity of cyber threats. In response, we introduce a bridging-the-gap ensemble framework especially for the network security applications. With the ensemble methods having an advanced framework, our proposed research will venture in this promising avenue with a sophisticated framework combining the prediction abilities of few models to reach higher accuracy, improved robustness, and generalizing ability [4]. The lower-level inbuilt models in our research come up as promising experts along with the ensemble approach. However, prior to the use of ensemble methods in predictive modeling, such research frequently falls short of an effective way to choose those individual models which are built into the ensemble [5–7]. Recognizing this crucial gap, the following proposes to breach this chasm by the introduction of a novel ensemble model that capitalizes on the strengths of well-established algorithms — XGBoost, Random Forest, Gradient Boosting, and Support Vector Machines. So, the basic idea of our approach is to develop a synergy ensemble model that simultaneously combines the strengths of both bagging and boosting techniques to enhance the robustness as well as predictive performances of the anomaly detection system [8]. Our proposed model, utilizing the NSL KDD dataset for in-depth analysis and evaluation, endeavors to achieve three of objectives: firstly, we aspire to cultivate an ensemble model that seamlessly

integrates the predictive prowess of diverse machine learning techniques for anomaly detection. Secondly, we ardently pursue the rigorous evaluation and comparative analysis of the proposed ensemble model against individual models, employing established metrics such as accuracy, precision, recall, and F1-score. Thirdly, we eagerly seek to impart profound insights into the effectiveness of ensemble methods in bolstering the robustness and generalization of anomaly detection systems within the intricate domain of network security. The experimental showcase the outstanding accuracy of 99.68 % in proposed ensemble model that demonstrating the efficacy of the model. This remarkable achievement presents a new frontier in the realm of ensemble methods, paving the way for accurate identification and classification of anomalies within network traffic.

## Literature Review

The field of network anomaly detection has witnessed significant evolution in response to the growing complexity of cyber threats and the escalating need for robust cybersecurity solutions. This study in [9] proposes a new method for network anomaly detection using a 5-layer Auto Encoder (AE) consisting of 1 input, 1 output followed by 2 dense and a bottleneck layer. The key feature is a data pre-processing step that tackles the issue of data imbalance. The authors' approach combats this by transforming and removing outliers that significantly skew the data. Another innovation lies in the model core: a new mean absolute error based reconstruction error function. This function plays a crucial role in classifying network traffic as normal or anomalous. The paper emphasizes that this function, combined with an optimal 5-layer AE architecture, allows for superior feature learning. By compressing the data into a lower-dimensional space, the model focuses on the most critical characteristics for anomaly detection. The authors tested their model on the NSL KDD dataset and achieved 90.61 % accuracy and 92.26 % F1-score in anomaly detection. Similar to this approach, another study [10] achieved an accuracy of 85 % using an AE model on the same NSL KDD dataset. In contrast, a different approach leveraging deep learning is presented by Bhavna et al. [11]. This study investigates a Convolutional Neural Network (CNN) model for Network Intrusion Detection Systems (NIDS). They also utilize the NSL KDD benchmark dataset, but their model focuses on four specific attack classes. To improve efficiency, they employ a filter-based feature reduction method to remove redundant features within the dataset. The core of their system is a 2D-CNN model, which achieves an impressive accuracy of 99.4 % with

reduced loss. The paper likely compares the performance of both models (AE and CNN) in terms of accuracy and other evaluation metrics providing valuable insights into the effectiveness of different deep learning architectures for NIDS tasks. Yet another deep learning approach is presented in [6], where the authors propose a model that combines the strengths of Bidirectional Long Short-Term Memory (BLSTM) and attention mechanism for anomaly detection. BLSTM is adept at learning the characteristics of network traffic data by analyzing sequential data like network packets. The attention mechanism refines this process by focusing on the most critical features within the BLSTM output, effectively identifying key aspects for traffic classification. However, this model achieves a lower accuracy of 84.25 % compared to the AE and CNN models discussed earlier. The exhaustive review of relevant literature is elucidated in a tabulated format in Table.

The novel contribution of this research lies in its thorough exploration of the comparative performance of ensemble learning techniques using bagging-boosting and neural network architectures in network anomaly detection. While previous studies have examined individual models, this research bridges the gap by undertaking a holistic analysis that encompasses both traditional and cutting-edge methodologies. However, existing anomaly detection methods [12] often struggle to achieve high accuracy and robustness due to the evolving nature of network threats.

This limitation can lead to missed attacks or false positives, hindering network security. Our proposed work addresses this challenge by proposing a novel ensemble model that leverages the strengths of established algorithms like XGBoost, Random Forest, Gradient Boosting, and Support Vector Machines. This hybrid approach aims to achieve superior accuracy and robustness in network anomaly detection. The emphasis on diverse model evaluation, trade-offs, and real-world applicability distinguishes this research from existing literature.

## Experiments

This section elucidates the proposed ensemble framework designed for anomaly detection within the dataset. Commencing with a detailed exposition on the utilized dataset and its preprocessing procedures, the subsequent discussion delves into the distinctive contributions of each phase within the proposed framework, as illustrated in Fig. 1.

### Dataset

The research harnesses the NSL KDD dataset, a pivotal benchmark in intrusion detection sourced from<sup>1</sup>. This dataset is refined and updated version of KDD Cup '99

<sup>1</sup> Available at: <https://www.unb.ca/cic/datasets/nsl.html> (accessed: 19.03.2024).

Table. Review of Prominent work done in Network Anomaly Detection

References	Research Focus	Techniques Used	Dataset	Accuracy, %
[6]	Network traffic-based Anomaly detection	BLSTM and an attention method	NSL KDD	84.25
[9]	Anomaly Detection Framework using AE	AE	NSL KDD	90.61
[11]	Internet of the Things (IoT) based IDS	CNN	NSL KDD	99.40
[10]	Deep Learning based Network Intrusion Detection Model	Deep AE	KDD Cup '99, NSL KDD	85 on the NSL KDD & 97.85 on the KDD Cup '99
[13]	Neural network-based Intrusion Detection System (IDS)	Long Short-Term Memory (LSTM)-Recurrent Neural Networks (RNN)	KDD Cup '99	93.82
[14]	LSTM RNN based IDS	LSTM-RNN	KDD Cup '99	96.93
[15]	Network traffic-based anomaly detection	Ensemble of Principal Component Analysis (PCA) fuzzy based KNN	NSL KDD	98.24
[16]	Network Traffic analysis for anomaly detection	Clustering based framework used	UNSW-NB 15, CICIDS2017	97.90
[17]	Intrusion Detection for Internet of Medical Things	Random Forest with Grid Search	Manual dataset	94.23
[12]	Anomaly Detection in SDN	Ensemble Approach based on RandomForestClassifier, ExtraTreeClassifier, AdaBoostClassifier, GradientBoostingClassifier and XGBoost	NSL KDD	Around 99
[18]	Anomaly detection framework to detect network traffic	Linear SVM (Support Vector Machine), multilayer perceptron (MLP), Naive Bayes (NB)	Three different manual datasets	96.90
[19]	Model developed to detect anomaly in Network intrusion detection	Generative adversarial networks	CIC IDS 2017	82

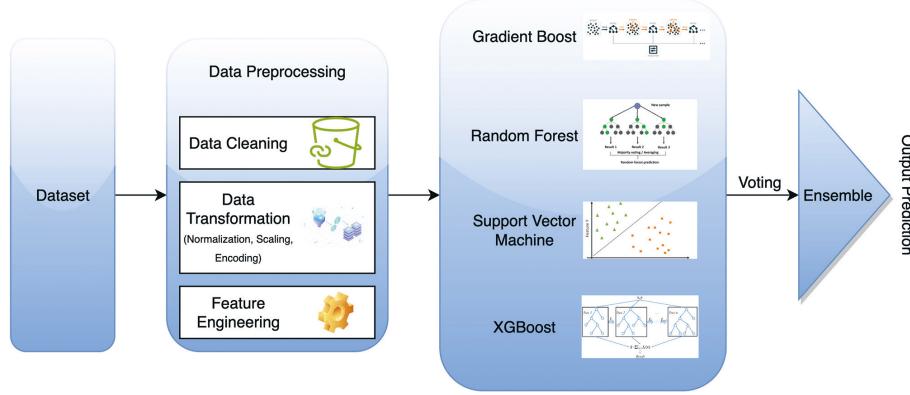


Fig. 1. Proposed ensemble model architecture

dataset [20], originally crafted by the Defense Advanced Research Projects Agency (DARPA), the NSL KDD dataset undergoes meticulous curation. Redundant and noisy data are expunged, and class balance is meticulously maintained, ensuring parity between normal and anomalous instances. The dataset contains two files namely training and test data. The dataset furnishes a rich substrate for analysis with 41 features encompassing network traffic intricacies, such as IP addresses, port numbers, and protocol types. It delineates between benign and malicious traffic as categorized into normal and attack facilitating nuanced anomaly detection.

Data preprocessing is executed meticulously to ensure the integrity and relevance of highly correlated features. The dataset under consideration amalgamates both training and test data, constituting a comprehensive repository of total 148,517 records. This amalgamation ensures a holistic representation of the data essential for training and evaluating the proposed ensemble-based anomaly detection model. Further, dataset is categorized into training and test data in the ratio of 60 % and 20 %, using train test split. An initial analytical overview provides a thorough examination of the dataset facilitating the categorization of attack types into distinct categories. The classification schema delineates attacks into five categories: Denial of Service (DoS), Probe, Remote-to-Local (R2L), User-to-Root (U2R), and Normal Traffic Data. This categorization framework underlies the subsequent anomaly detection methodologies to enable the model in perceiving and classifying diverse attack patterns. The standard preprocessing pipeline is further invoked here to fortify the dataset against inherent challenges and enhance its suitability for modeling. From correlation, the data features are sorted where by only features that have a higher correlation with each other were extracted. This is due to multifaceted approach commencing with handling of missing values in order data completeness. Numerical features are normalized and scaled, an indispensable step to make their scales in harmony and to contribute to model stability. One hot encoding is preferred instead of label encoding so as to prevent arbitrary order in categorical variables. One-hot encoding is the transformation process applied in subjecting categorical variables so that one can be able to represent the former in a form suitable for training machine learning models. Through this approach, information of categorical nature remains intact but at

the same time becomes suitable with numerical-based algorithms. Another refinement involves the judicious elimination of irrelevant columns streamlining of the dataset to reduce such risk of complexities emanating from dimensionality. Further distillation of the dataset is performed through a feature selection endeavor and gave way to retaining the top 30 most highly correlated features. These features<sup>1</sup> capture the dataset essence that pertains to the salient information important in the anomaly detection task.

### Ensemble Model Architecture

Using a rich tapestry of machine learning algorithms, ranging from XGBoost, Random Forest, Gradient Boosting, as well as SVM, the ensemble model is seamlessly woven into an integrated ensemble structure. The synergistic interplay of the models taps their respective architectural strengths, each contributing a unique vantage point in the intricate task of anomaly detection. These machine learning algorithms selected judiciously considering pros and cons of each model and tested them with Grid search algorithm. Gradient boosting methodology that XGBoost follows boosts its caliber to capture intricate patterns. Random Forest works against overfitting due to the use of decision trees. Gradient Boosting tunes for refining predictions sequentially, and SVM is known for its discriminative decision boundaries. This combination guarantees an almost exhaustive coverage of possible patterns in the data for variance in complexities.

The proposed ensemble approach for enhanced anomaly detection in network security leverages a comprehensive integration of bagging and boosting techniques, as illustrated in Fig. 1. The dataset undergoes a sequential passage through each model within the ensemble allowing for the exploitation of their individual strengths and capabilities. This strategic sequencing enables the ensemble to derive meaningful insights from the data while maximizing the detection of anomalous patterns. Central to our approach is the pre-training of the ensemble base classifier using the dataset. This initial training phase ensures that the ensemble is equipped with a foundational understanding of both normal and anomalous network behaviors. Once trained, the ensemble operates as a

<sup>1</sup> Available at: <https://drive.google.com/file/d/13tahTGhvxb-1wzlefe3Nt1pMZnLkplbo/view> (accessed: 19.03.2024).

cohesive unit, collectively analyzing incoming data to identify potential anomalies. Each base classifier within the ensemble evaluates the data independently, generating predictions that encompass both the predicted label and the posterior probability of samples. This holistic assessment enables the ensemble to capture a comprehensive view of the data landscape, enhancing its anomaly detection capabilities. The innovative aspect of our approach is the incorporation of a sophisticated weighted voting scheme which enhances the ensemble decision-making process. In order to determine the weight assigned to each model in the ensemble, we utilize a weighted voting mechanism based on accuracy performance metrics. The process begins with the evaluation of individual model accuracy on the training data. Each model is trained on the pre-processed training data, and its accuracy is assessed based on its ability to correctly classify data points as normal or anomalous. These accuracy scores serve as the basis for weight assignment, reflecting the relative performance of each model.

The weight assignment process takes into account both the priority of each model and its accuracy performance. Priority is assigned based on the significance of each model contribution to the ensemble, with higher priority models receiving greater weights. For example, XGBoost, with its superior ability to capture complex patterns, may be assigned the highest weight, followed by Gradient Boosting, Random Forest, and Support Vector Classifier (SVC). The weights are assigned proportionally to the accuracy scores ensuring that models with higher accuracy contribute more significantly to the final decision-making process. The justification for this weight assignment scheme lies in the balance between accuracy and the unique characteristics of each model. Models like XGBoost and Gradient Boosting, with their ability to handle complex patterns, are likely to achieve higher accuracy scores. Random Forest, while potentially having slightly lower accuracy, plays a crucial role in preventing overfitting and improving generalization. SVC, with its interpretable decision boundaries, have slightly lower accuracy compared to other models but still contributes valuable insights to the ensemble. The ensemble model operates in a sequential manner, with the results of each base classifier cascading into the subsequent voting mechanism. This iterative process not only ensures comprehensive data analysis but also effectively neutralizes the idiosyncrasies associated with individual models. Moreover, the ensemble adopts a soft voting mechanism, departing from rigid binary voting strategies. This nuanced decision-making process takes into account the confidence levels of each individual model, thereby enhancing adaptability to uncertain or ambiguous scenarios.

Once weights are assigned to each model, the weighted voting process is employed to combine the predictions of individual models and make the final decision on anomaly detection. For each data point in the test set, the predicted class label (1 for normal, 0 for anomaly) from each model is multiplied by its corresponding weight. The weighted votes across all models are then summed, and the sum is compared to a predefined threshold (e.g., 0.5). If the sum exceeds or equals the threshold, the final ensemble

prediction is labeled as “normal”; otherwise, it’s classified as “anomaly”.

### **A Comprehensive Ensemble Approach Integrating Bagging and Boosting Techniques**

Our proposed ensemble approach implementation requires a rigorous process that allows each individual model in the ensemble to deliver optimal performance. We used the grid search algorithm with a more sophisticated method of hyperparameters tuning. This method scans through each defined space of hyperparameters extensively, thus covering all possible configurations for each of the models making up the ensemble in a systematic manner. The grid search algorithm took nearly 12 hours to get the final parameters that were used in this study. The settings of hyperparameters for individual models are carefully selected to balance between complexity and performance. The Gradient Boosting Classifier, Random Forest Classifier, SVC (with a linear kernel and  $C = 0.1$ ), and XGBoost Classifier serve as the foundational models within our ensemble. Their parameter configurations are fine-tuned to optimize their individual contributions. We set the number of trees ( $n\_estimators$ ) to 200 for both Gradient Boosting and Random Forest algorithms. This parameter controls the complexity of the ensemble model by determining the number of decision trees used in the final prediction. Additionally, the maximum depth ( $max\_depth$ ) of each tree is set to 20 for both algorithms. This parameter limits the maximum number of splits allowed in each tree, preventing them from becoming overly complex and potentially overfitting the training data. For the SVC, the regularization parameter ( $C$ ) is set to 0.1. This parameter controls the trade-off between fitting the training data and keeping the model generalizable. Finally, the XGBoost Classifier utilizes a combination of  $n\_estimators$  (200),  $max\_depth$  (6), and  $learning\_rate$  (0.3). The  $learning\_rate$  parameter controls the step size taken when the model updates its internal parameters during training.

In preparation for training, the ensemble model was trained on pre-processed training dataset whereby all models learn diverse patterns that describe both normal and anomalous network behaviors. The intention is to make complex knowledge of the data set available to the ensemble so as to improve its anomaly detection ability. After that, we have thoroughly evaluated how our model performs using a test set which serves as an important evaluation criterion for its generalization capability. This evaluation phase involves assessing the model ability to extrapolate its learned patterns to unseen data.

### **Experimental Setup**

The experimental setup for this research leveraged Google Collaboratory, a cloud-based Integrated Development Environment (IDE), for model execution. The utilization of a robust GPU within Google Collaboratory substantially reduced the training time for the proposed ensemble model. The values essential for computations were derived from the Google Compute Engine backend specifically utilizing a GPU. The system RAM usage reached 2.7 GB, representing a fraction of the total 12.7 GB capacity. The GPU, identified as an NVIDIA Tesla T4, played a pivotal role in enhancing computational efficiency. Furthermore, the disk space allocation amounted

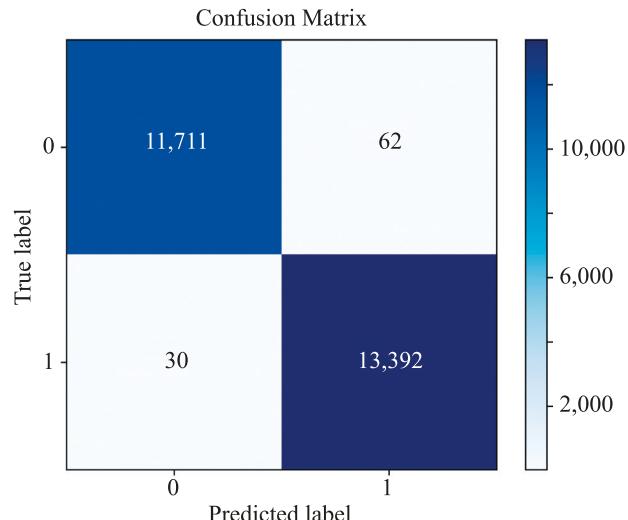


Fig. 2. Confusion matrix of proposed model

to 21.3 GB out of a total capacity of 78.2 GB, ensuring ample storage for the seamless execution of the research.

## Results

### Performance Evaluation Metrics

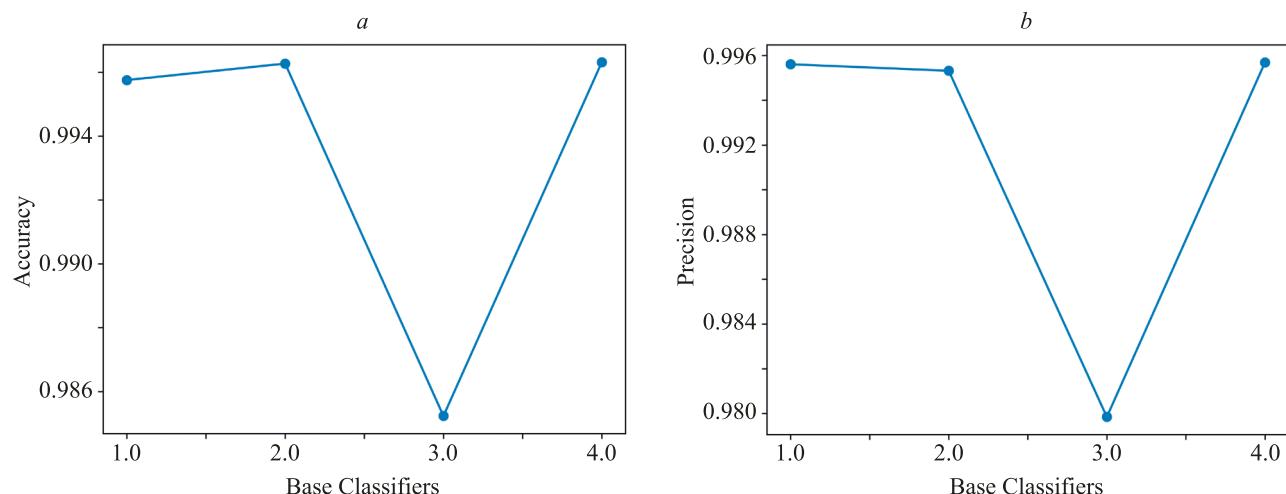
The evaluation of our ensemble model was carried out with the full suite of performance metrics. The metrics that we considered for the evaluation of our research are accuracy, precision, recall, F1-score and Area Under the Receiver Operating Characteristic curve (AUC-ROC). These we used together to detect anomaly accurately while reducing false positive and false negatives.

Accuracy is a fundamental metric to find the overall correctness of predictions. Hence precision becomes crucial when considering false positives cost measuring as an anomaly equivalent model accuracy. Moreover, recall measures how much the model is able to discover all the actual anomalies, pointing out the true positives ratio among all positive actual cases. F1-score chose to combine precision and recall in order to provide a measure balanced, extremely valuable especially for imbalanced datasets. The AUC-ROC is crucial in the analysis of

performance associated with binary classification tasks. Actually, it is one of the performance measures and hence forms a foundation upon whose foundation other performance measures are established against. The ROC curve plots the relation between true positive rate and false positive rate at various decision thresholds. AUC-ROC quantifies the discriminatory ability of the model where the better model discriminating normal and anomalous instances tends to have higher values. Also, log loss depicts the overall loss during the training of the model and guarantees the correctness of the model. Together, these metrics collectively produce a nuanced evaluation allowing comprehensively understand strengths and limitations of an anomaly detection model [21].

The accuracy of proposed model showcase its proficiency, boasting a remarkable achievement of 99.68 %. This numerical testament underscores the model adeptness in distinguishing between normal and anomalous instances within the dataset. Fig. 3, *a* provided a holistic view of the model overall predictive correctness, portraying a trajectory of consistently high accuracy across different scenarios. The confusion matrix plot as depicted in Fig. 2 dissected the model classification outcomes, delineating true positives, false positives, true negatives, and false negatives with granular precision. The model extends its performance in terms of precision, F1-score and recall as 99.54, 99.66 and 99.78 as shown in Fig. 3, *b*, Fig. 4, *a* and Fig. 4, *b* respectively. On the other hand, the model ability to balance precision and recall, encapsulated by the F1-score plot, attested to its equilibrium in minimizing false positives and false negatives is shown in Fig. 4, *a*. The Log Loss plot furnished a nuanced depiction of the model calibration, capturing the intricacies of probability estimation. The Log Loss of model showing the training loss over base classifiers are depicted in Fig. 5, *a*.

Precision and recall, vital cogs in anomaly detection, were graphically articulated through dedicated precision and recall plots. These visual aids elucidated the trade-off between accurately identified anomalies and potential false positives. The quintessential AUC-ROC plots encapsulated the model discriminatory power across varying thresholds, offering a comprehensive view of its true positive rate against false positive rate is depicted in Fig. 5, *b*.

Fig. 3. Accuracy (*a*) and Precision (*b*) vs. base classifiers in the proposed ensemble approach

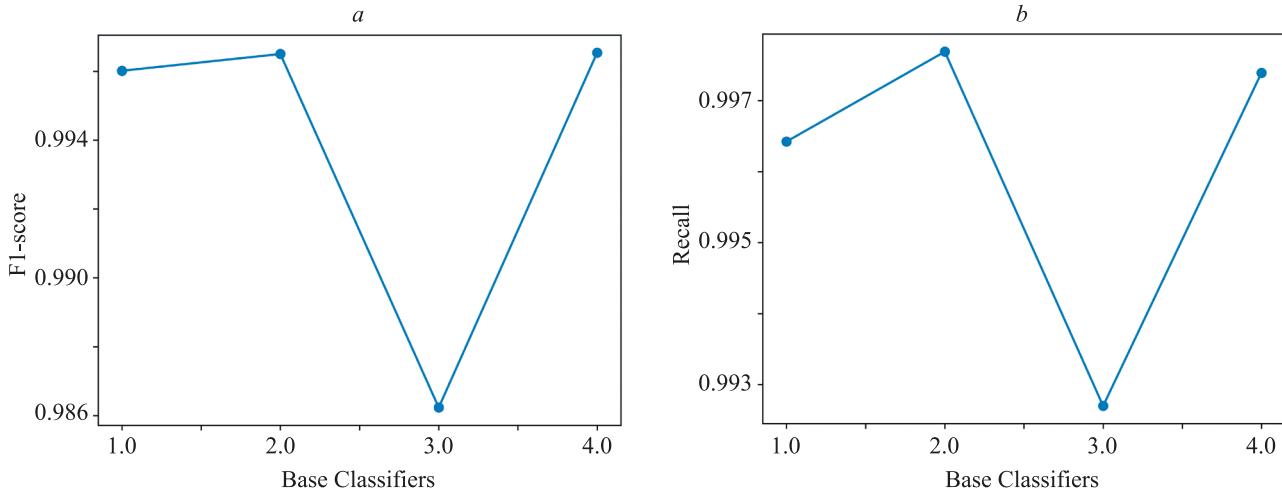


Fig. 4. F1-score (a) and Recall (b) vs. base classifiers in the proposed ensemble approach

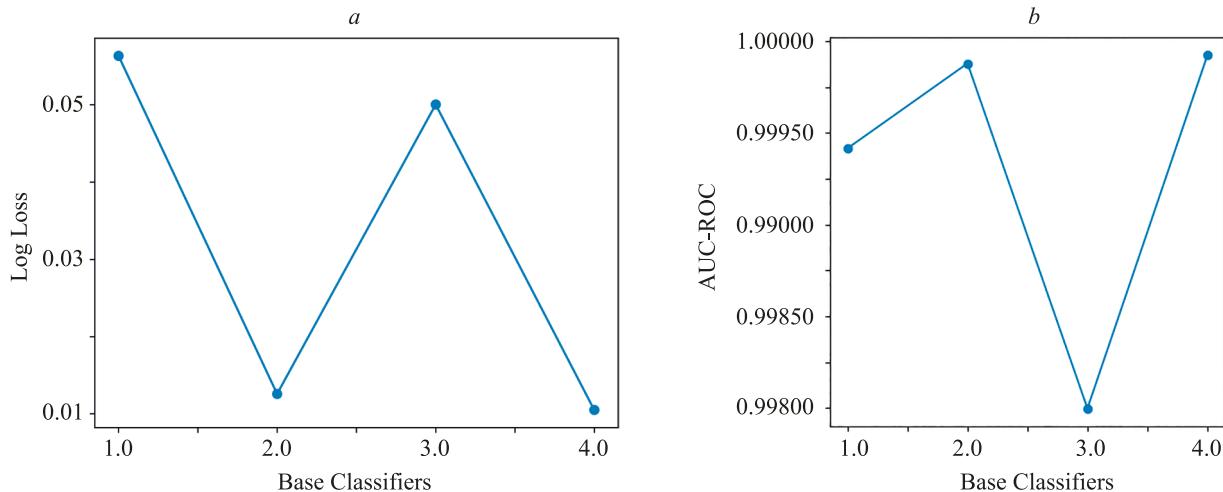


Fig. 5. Log Loss (a) and AUC-ROC (b) vs. base classifiers in the proposed ensemble approach

### Comparative Study

We take into account the previous work from [9–11, 22–25] to compare our research. Our model achieves an accuracy of 99.68 %, far better than existing [9] and [11] benchmarks. In addition, our proposed ensemble models excel in precision, recall and F1-score, demonstrated by its sturdiness across a variety of indicators. Notably, in comparison with the methods noted in [22–25], the proposed framework showed a degree of superiority. This shows that it is adept at dealing with some of the mettle test entailed by anomaly detection. The nuanced comparison underscores the significance of our proposed ensemble model in advancing the state-of-the-art in anomaly detection.

### Conclusion

In conclusion, the study introduces a solid ensemble framework for the anomaly detection attempts exploiting the fusion of different base classifiers within a complex voting mechanism. The careful choice of dataset and individual models in ensemble approach commences the building of a holistic analysis. The Gradient Boosting, Random Forest, Support Vector Machine, and XGBoost

brought as base classifiers that enhance the discernment of ensemble capture the subtler patterns on aggregation. The presented ensemble is one capable model described through a rigorous evaluation with key metrics and produced effective results. The theatrics show that the proposed framework is able to capture anomalies within the dataset very effectively with an accuracy of 99.68 %. The binary classification indicative of anomaly presence for the ensemble indicates the offered practical utility of the ensemble in real world scenarios.

Even though this contributes quite a lot to network anomaly detection, our research has its own limitations. Here are some of them. First, the study is delimited to a specific dataset that may impact making generalization between this result and those that exist in other network environment. Lack of real-time experimentation and elimination of hybrid models preclude dynamic adaptations that are bound to evolving threats. Stronger understanding of adversarial attacks and concurrent deployment is an essential booster to the resilience in our model. This is further the temporal characteristic of network behavior that could best be served by temporal analysis and online learning methodologies.

## References

1. Reichenbach M. New challenges in electronic payments. *Intelligent Enterprises of the 21st Century*. Ed. by J.N.D. Gupta, S. Sharma. IGI Global, 2004, pp. 153–162. <https://doi.org/10.4018/9781591401605.ch010>
2. Kebande V.R., Karie N.M., Ikuesan R.A. Real-time monitoring as a supplementary security component of vigilantism in modern network environments. *International Journal of Information Technology*, 2021, vol. 13, no. 1, pp. 5–17. <https://doi.org/10.1007/s41870-020-00585-8>
3. Hareesh R., Senthil Kumar R.K., Kalluri R., Bindhumadhava B.S. Critical infrastructure asset discovery and monitoring for cyber security. *Lecture Notes in Electrical Engineering*, 2022, vol. 847, pp. 289–300. [https://doi.org/10.1007/978-981-16-9008-2\\_27](https://doi.org/10.1007/978-981-16-9008-2_27)
4. Savage D., Zhang X., Yu X., Chou P., Wang Q. Anomaly detection in online social networks. *Social Networks*, 2014, vol. 39, pp. 62–70. <https://doi.org/10.1016/j.socnet.2014.05.002>
5. Benaddi H., Ibrahimi K., Benslimane A. Improving the intrusion detection system for NSL-KDD dataset based on PCA-fuzzy clustering-KNN. *Proc. of the 6th International Conference on Wireless Networks and Mobile Communications (WINCOM)*, 2018, pp. 1–6. <https://doi.org/10.1109/wincom.2018.8629718>
6. Su T., Sun H., Zhu J., Wang S., Li Y. BAT: Deep learning methods on network intrusion detection using NSL-KDD dataset. *IEEE Access*, 2020, vol. 8, pp. 29575–29585. <https://doi.org/10.1109/access.2020.2972627>
7. Wang C., Zhou H., Hao Z., Hu S., Li J., Zhang X., Jiang B., Chen X. Network traffic analysis over clustering-based collective anomaly detection. *Computer Networks*, 2022, vol. 205, pp. 108760. <https://doi.org/10.1016/j.comnet.2022.108760>
8. Keim Y., Mohapatra A.K. Cyber threat intelligence framework using advanced malware forensics. *International Journal of Information Technology*, 2022, vol. 14, no. 1, pp. 521–530. <https://doi.org/10.1007/s41870-019-00280-3>
9. Xu B., Jang-Jaccard J., Singh A., Wei Y., Sabrina F. Improving performance of autoencoder-based network anomaly detection on nsl-kdd dataset. *IEEE Access*, 2021, vol. 9, pp. 140136–140146. <https://doi.org/10.1109/access.2021.3116612>
10. Shone N., Ngoc T.N., Phai V.D., Shi Q. A deep learning approach to network intrusion detection. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2018, vol. 2, no. 1, pp. 41–50. <https://doi.org/10.1109/tctci.2017.2772792>
11. Sharma B., Sharma L., Lal C. Anomaly based network intrusion detection for IoT attacks using convolution neural network. *Proc. of the IEEE 7th International Conference for Convergence in Technology (I2CT)*, 2022, pp. 1–6. <https://doi.org/10.1109/i2ct54291.2022.9824229>
12. Krzemień W., Jędrasiak K., Nawrat A. Anomaly detection in software defined networks using ensemble learning. *Lecture Notes in Networks and Systems*, 2022, vol. 439, pp. 629–643. [https://doi.org/10.1007/978-3-030-98015-3\\_44](https://doi.org/10.1007/978-3-030-98015-3_44)
13. Staudemeyer R.C. Applying long short-term memory recurrent neural networks to intrusion detection. *South African Computer Journal*, 2015, vol. 56, pp. 136–154. <https://doi.org/10.18489/sacj.v56i1.248>
14. Kim J., Kim J., Thu H.L.T., Kim H. Long short term memory recurrent neural network classifier for intrusion detection. *Proc. of the International Conference on Platform Technology and Service (PlatCon)*, 2016, pp. 1–5. <https://doi.org/10.1109/platcon.2016.7456805>
15. Liu Z., Thapa N., Shaver A., Roy K., Yuan X., Khorsandoo S. Anomaly detection on IoT network intrusion using machine learning. *Proc. of the International Conference on Artificial Intelligence, Big Data, Computing and Data Communication Systems (ICABCD)*, 2020, pp. 1–5. <https://doi.org/10.1109/icabcd49160.2020.9183842>
16. Khan W., Haroon M. An unsupervised deep learning ensemble model for anomaly detection in static attributed social networks. *International Journal of Cognitive Computing in Engineering*, 2022, vol. 3, pp. 153–160. <https://doi.org/10.1016/j.ijcce.2022.08.002>
17. Gupta K., Sharma D.K., Gupta K.D., Kumar A. A tree classifier based network intrusion detection model for Internet of Medical Things. *Computers and Electrical Engineering*, 2022, vol. 102, pp. 108158. <https://doi.org/10.1016/j.compeleceng.2022.108158>
18. Ma Q., Sun C., Cui B. A novel model for anomaly detection in network traffic based on support vector machine and clustering. *Security and Communication Networks*, 2021, pp. 170788. <https://doi.org/10.1155/2021/2170788>

## Литература

1. Reichenbach M. New challenges in electronic payments // Intelligent Enterprises of the 21st Century / ed. by J.N.D. Gupta, S. Sharma. IGI Global, 2004. P. 153–162. <https://doi.org/10.4018/9781591401605.ch010>
2. Kebande V.R., Karie N.M., Ikuesan R.A. Real-time monitoring as a supplementary security component of vigilantism in modern network environments // International Journal of Information Technology. 2021. V. 13. N 1. P. 5–17. <https://doi.org/10.1007/s41870-020-00585-8>
3. Hareesh R., Senthil Kumar R.K., Kalluri R., Bindhumadhava B.S. Critical infrastructure asset discovery and monitoring for cyber security // Lecture Notes in Electrical Engineering. 2022. V. 847. P. 289–300. [https://doi.org/10.1007/978-981-16-9008-2\\_27](https://doi.org/10.1007/978-981-16-9008-2_27)
4. Savage D., Zhang X., Yu X., Chou P., Wang Q. Anomaly detection in online social networks // Social Networks. 2014. V. 39. P. 62–70. <https://doi.org/10.1016/j.socnet.2014.05.002>
5. Benaddi H., Ibrahimi K., Benslimane A. Improving the intrusion detection system for NSL-KDD dataset based on PCA-fuzzy clustering-KNN // Proc. of the 6th International Conference on Wireless Networks and Mobile Communications (WINCOM). 2018. P. 1–6. <https://doi.org/10.1109/wincom.2018.8629718>
6. Su T., Sun H., Zhu J., Wang S., Li Y. BAT: Deep learning methods on network intrusion detection using NSL-KDD dataset // IEEE Access. 2020. V. 8. P. 29575–29585. <https://doi.org/10.1109/access.2020.2972627>
7. Wang C., Zhou H., Hao Z., Hu S., Li J., Zhang X., Jiang B., Chen X. Network traffic analysis over clustering-based collective anomaly detection // Computer Networks. 2022. V. 205. P. 108760. <https://doi.org/10.1016/j.comnet.2022.108760>
8. Keim Y., Mohapatra A.K. Cyber threat intelligence framework using advanced malware forensics // International Journal of Information Technology. 2022. V. 14. N 1. P. 521–530. <https://doi.org/10.1007/s41870-019-00280-3>
9. Xu B., Jang-Jaccard J., Singh A., Wei Y., Sabrina F. Improving performance of autoencoder-based network anomaly detection on nsl-kdd dataset // IEEE Access. 2021. V. 9. P. 140136–140146. <https://doi.org/10.1109/access.2021.3116612>
10. Shone N., Ngoc T.N., Phai V.D., Shi Q. A deep learning approach to network intrusion detection // IEEE Transactions on Emerging Topics in Computational Intelligence. 2018. V. 2. N 1. P. 41–50. <https://doi.org/10.1109/tctci.2017.2772792>
11. Sharma B., Sharma L., Lal C. Anomaly based network intrusion detection for IoT attacks using convolution neural network // Proc. of the IEEE 7th International Conference for Convergence in Technology (I2CT). 2022. P. 1–6. <https://doi.org/10.1109/i2ct54291.2022.9824229>
12. Krzemień W., Jędrasiak K., Nawrat A. Anomaly detection in software defined networks using ensemble learning // Lecture Notes in Networks and Systems. 2022. V. 439. P. 629–643. [https://doi.org/10.1007/978-3-030-98015-3\\_44](https://doi.org/10.1007/978-3-030-98015-3_44)
13. Staudemeyer R.C. Applying long short-term memory recurrent neural networks to intrusion detection // South African Computer Journal. 2015. V. 56. P. 136–154. <https://doi.org/10.18489/sacj.v56i1.248>
14. Kim J., Kim J., Thu H.L.T., Kim H. Long short term memory recurrent neural network classifier for intrusion detection // Proc. of the International Conference on Platform Technology and Service (PlatCon). 2016. P. 1–5. <https://doi.org/10.1109/platcon.2016.7456805>
15. Liu Z., Thapa N., Shaver A., Roy K., Yuan X., Khorsandoo S. Anomaly detection on IoT network intrusion using machine learning // Proc. of the International Conference on Artificial Intelligence, Big Data, Computing and Data Communication Systems (ICABCD). 2020. P. 1–5. <https://doi.org/10.1109/icabcd49160.2020.9183842>
16. Khan W., Haroon M. An unsupervised deep learning ensemble model for anomaly detection in static attributed social networks // International Journal of Cognitive Computing in Engineering. 2022. V. 3. P. 153–160. <https://doi.org/10.1016/j.ijcce.2022.08.002>
17. Gupta K., Sharma D.K., Gupta K.D., Kumar A. A tree classifier based network intrusion detection model for Internet of Medical Things // Computers and Electrical Engineering. 2022. V. 102. P. 108158. <https://doi.org/10.1016/j.compeleceng.2022.108158>
18. Ma Q., Sun C., Cui B. A novel model for anomaly detection in network traffic based on support vector machine and clustering // Security and Communication Networks. 2021. P. 170788. <https://doi.org/10.1155/2021/2170788>
19. Iliyasu A.S., Deng H. N-GAN: a novel anomaly-based network intrusion detection with generative adversarial networks //

19. Iliyasu A.S., Deng H. N-GAN: a novel anomaly-based network intrusion detection with generative adversarial networks. *International Journal of Information Technology*, 2022, vol. 14, no. 7, pp. 3365–3375. <https://doi.org/10.1007/s41870-022-00910-3>
20. Tavallae M., Bagheri E., Lu W., Ghorbani A.A. A detailed analysis of the KDD CUP 99 data set. *Proc. of the IEEE Symposium on Computational Intelligence for Security and Defense Applications*, 2009, pp. 1–6. <https://doi.org/10.1109/cisda.2009.5356528>
21. Panesar A. Evaluating machine learning models. *Machine Learning and AI for Healthcare*. Apress, Berkeley, CA, 2021, pp. 189–205. [https://doi.org/10.1007/978-1-4842-6537-6\\_7](https://doi.org/10.1007/978-1-4842-6537-6_7)
22. Assy A.T., Mostafa Y., Abd El-khaleq A., Mashaly M. Anomaly-based intrusion detection system using one-dimensional convolutional neural network. *Procedia Computer Science*, 2023, vol. 220, pp. 78–85. <https://doi.org/10.1016/j.procs.2023.03.013>
23. Acharya T., Annamalai A., Chouikha M.F. Efficacy of bidirectional LSTM model for network-based anomaly detection. *Proc. of the IEEE 13<sup>th</sup> Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, 2023, pp. 336–341. <https://doi.org/10.1109/iscaie57739.2023.10165336>
24. Kavitha S., Uma Maheswari N., Venkatesh R. Network anomaly detection for NSL-KDD dataset using deep learning. *Information Technology in Industry*, 2021, vol. 9, no. 2, pp. 821–827. <https://doi.org/10.17762/itii.v9i2.419>
25. Gadali S., Mokhtar R., Abdelhaq M., Alsaqour R., Ali E.S., Saeed R. Machine learning-based anomaly detection using K-mean array and sequential minimal optimization. *Electronics*, 2022, vol. 11, no. 14, pp. 2158. <https://doi.org/10.3390/electronics11142158>
26. International Journal of Information Technology. 2022. V. 14. N 7. P. 3365–3375. <https://doi.org/10.1007/s41870-022-00910-3>
27. Tavallae M., Bagheri E., Lu W., Ghorbani A.A. A detailed analysis of the KDD CUP 99 data set // Proc. of the IEEE Symposium on Computational Intelligence for Security and Defense Applications. 2009. P. 1–6. <https://doi.org/10.1109/cisda.2009.5356528>
28. Panesar A. Evaluating machine learning models // Machine Learning and AI for Healthcare. Apress, Berkeley, CA, 2021. P. 189–205. [https://doi.org/10.1007/978-1-4842-6537-6\\_7](https://doi.org/10.1007/978-1-4842-6537-6_7)
29. Assy A.T., Mostafa Y., Abd El-khaleq A., Mashaly M. Anomaly-based intrusion detection system using one-dimensional convolutional neural network // Procedia Computer Science. 2023. V. 220. P. 78–85. <https://doi.org/10.1016/j.procs.2023.03.013>
30. Acharya T., Annamalai A., Chouikha M.F. Efficacy of bidirectional LSTM model for network-based anomaly detection // Proc. of the IEEE 13<sup>th</sup> Symposium on Computer Applications & Industrial Electronics (ISCAIE). 2023. P. 336–341. <https://doi.org/10.1109/iscaie57739.2023.10165336>
31. Kavitha S., Uma Maheswari N., Venkatesh R. Network anomaly detection for NSL-KDD dataset using deep learning // Information Technology in Industry. 2021. V. 9. N 2. P. 821–827. <https://doi.org/10.17762/itii.v9i2.419>
32. Gadali S., Mokhtar R., Abdelhaq M., Alsaqour R., Ali E.S., Saeed R. Machine learning-based anomaly detection using K-mean array and sequential minimal optimization // Electronics. 2022. V. 11. N 14. P. 2158. <https://doi.org/10.3390/electronics11142158>

## Authors

**Rashmikiran Pandey** — PhD Student, Moscow Institute of Physics and Technology (National Research University), Moscow region, Dolgoprudny, 141701, Russian Federation,  58122041300, [https://orcid.org/0000-0003-0042-6565, rashmikiran@phystech.edu](mailto:rashmikiran@phystech.edu)

**Mrinal Pandey** — PhD Student, Moscow Institute of Physics and Technology (National Research University), Moscow region, Dolgoprudny, 141701, Russian Federation,  58425838700, [https://orcid.org/0009-0009-5151-6908, mrinalpandei@phystech.edu](mailto:mrinalpandei@phystech.edu)

**Alexey N. Nazarov** — D.Sc., Professor, Federal Research Center “Computer Science and Control” of the Russian Academy of Sciences, Moscow, 119333, Russian Federation,  7201780424, [https://orcid.org/0000-0002-0497-0296, a.nazarov06@bk.ru](mailto:a.nazarov06@bk.ru)

## Авторы

**Рашмикриран Пандей** — аспирант, Московский физико-технический институт (национальный исследовательский университет), Московская область, Долгопрудный, 141701, Российская Федерация,  58122041300, [https://orcid.org/0000-0003-0042-6565, rashmikiran@phystech.edu](mailto:rashmikiran@phystech.edu)

**Пандей Мринал** — аспирант, Московский физико-технический институт (национальный исследовательский университет), Московская область, Долгопрудный, 141701, Российская Федерация,  58425838700, [https://orcid.org/0009-0009-5151-6908, mrinalpandei@phystech.edu](mailto:mrinalpandei@phystech.edu)

**Назаров Алексей Николаевич** — доктор технических наук, профессор, Федеральный исследовательский центр «Информатика и управление» Российской академии наук, Москва, 119333, Российская Федерация,  7201780424, [https://orcid.org/0000-0002-0497-0296, a.nazarov06@bk.ru](mailto:a.nazarov06@bk.ru)

Received 08.01.2024

Approved after reviewing 26.07.2024

Accepted 16.09.2024

Статья поступила в редакцию 08.01.2024

Одобрена после рецензирования 26.07.2024

Принята к печати 16.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-797-805

## Enhancing attribute-based access control with Ethereum and ZK-SNARK technologies

Maher Maalla<sup>1</sup>, Sergey V. Bezzateev<sup>2✉</sup>

<sup>1,2</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>2</sup> Saint Petersburg State University of Aerospace Instrumentation, Saint Petersburg, 190000, Russian Federation

<sup>1</sup> [maher.malla7@gmail.com](mailto:maher.malla7@gmail.com), <https://orcid.org/0000-0002-4806-8608>

<sup>2</sup> [bsv@guap.ru✉](mailto:bsv@guap.ru), <https://orcid.org/0000-0002-0924-6221>

### Abstract

Attribute Based Access Control (ABAC) is one of the most efficient, scalable, and well-used access control. It's based on attributes not on users, but even when the users want to get access to some resource, they must submit their attributes for the verification process which may reveal the privacy of the users. Many research papers suggest blockchain-based ABAC which provides an immutable and transparent access control system. However, the privacy of the system may be compromised depending on the nature of the attributes. A Zero-Knowledge Proof, Ethereum-Based Access Control (ZK-ABAC) is proposed in this paper to simplify the management of access to the devices/objects and provide an efficient and immutable platform that keeps track of all actions and access management and preserve the privacy of the attributes. Our ZK-ABAC model utilizes smart contracts to facilitate access control management, Zero-Knowledge Succinct Non-Interactive Argument of Knowledge (ZK-SNARK) protocol to add privacy to attributes, InterPlanetary File System (IPFS) network to provide distributed storage system, and Chainlink to manage communications and data between on/off-chain systems. Comprehensive experiments and tests were conducted to evaluate the performance of our model, including the implementation of ZK-SNARK on the Ethereum blockchain. The results demonstrated the scalability challenges in the setup and proving phases, as well as the efficiency gains in the verification phase, particularly when scaled to higher numbers of users. These findings underscore the practical viability of our ZK-ABAC model for secure and privacy-preserving access control in decentralized environments.

### Keywords

ABAC, Ethereum, ZK-SNARK, zero-knowledge proofs, privacy, blockchain

**For citation:** Maalla M., Bezzateev S.V. Enhancing attribute-based access control with Ethereum and ZK-SNARK technologies. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 797–805. doi: 10.17586/2226-1494-2024-24-5-797-805

УДК 004.056.55

## Усовершенствование контроля доступа на основе атрибутов с помощью технологий Ethereum и ZK-SNARK

Махер Маала<sup>1</sup>, Сергей Валентинович Беззатеев<sup>2✉</sup>

<sup>1,2</sup> Университет ИТМО, Санкт-Петербург, 197101, Российской Федерации

<sup>2</sup> Санкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург, 190000, Российской Федерации

<sup>1</sup> [maher.malla7@gmail.com](mailto:maher.malla7@gmail.com), <https://orcid.org/0000-0002-4806-8608>

<sup>2</sup> [bsv@guap.ru✉](mailto:bsv@guap.ru), <https://orcid.org/0000-0002-0924-6221>

### Аннотация

Система разграничения доступа на основе атрибутов (Attribute-Based Access Control, ABAC) — одна из наиболее эффективных и широко используемых систем контроля доступа, обеспечивающая масштабируемость. Когда пользователи хотят получить доступ к информационному ресурсу, им необходимо предоставить свои атрибуты для процесса верификации, что может, в свою очередь, раскрыть их личные данные. Во многих

© Maalla M., Bezzateev S.V., 2024

исследовательских работах предлагается контроль доступа, основанный на атрибутах, использующий блокчейн, что обеспечивает защищенную от искажений (Zero-Knowledge, ZK) и прозрачную систему контроля доступа. Однако конфиденциальность системы может быть нарушена в зависимости от характера атрибутов. В работе предлагается использовать систему контроля доступа на основе Ethereum и доказательств без разглашения (ZK-ABAC). Система упрощает управление доступом к устройствам/объектам, обеспечивает эффективную и защищенную от искажений платформу, контролирующую все действия и управление доступом. При этом сохраняется конфиденциальность атрибутов. Предлагаемая модель контроля доступа на основе технологии ZK-ABAC использует смарт-контракты для управления доступом. Протокол ZK-SNARK обеспечивает конфиденциальность атрибутов пользователей. Система InterPlanetary File System применяется для создания распределенной системы хранения данных, а Chainlink для управления связью и данными между внутренними/внешними блокчейн-системами. Для оценки работоспособности предложенной модели проведены эксперименты и тесты, включая использование ZK-SNARK с блокчейн-технологией Ethereum. Результаты экспериментов продемонстрировали проблемы масштабируемости на этапах настройки и проверки, а также повышение эффективности на этапе верификации при масштабировании для большего числа пользователей. Полученные результаты подтвердили практическую эффективность предложенной модели ZK-ABAC для безопасного управления доступом с сохранением конфиденциальности в децентрализованных средах.

#### Ключевые слова

контроль доступа, основанный на атрибутах (ABAC), ZK-SNARK, доказательство без разглашения, конфиденциальность, блокчейн

**Ссылка для цитирования:** Маалла М., Беззатеев С.В. Усовершенствование контроля доступа на основе атрибутов с помощью технологий Ethereum и ZK-SNARK // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 797–805 (на англ. яз.). doi: 10.17586/2226-1494-2024-24-5-797-805

## Introduction

The importance of user privacy has garnered increasing attention, particularly in the era of social media and the alleged privacy violations by large technology companies seeking market dominance. Incorporating privacy features into access control systems has become a critical requirement, especially when dealing with highly sensitive information, financial records, and public blockchain platforms where data is immutable and visible to all participants. Furthermore, the integration of Attribute-Based Access Control (ABAC) with blockchain technology, which leverages the immutability characteristic of blockchains, necessitates a method to preserve user privacy when submitting attributes to smart contracts for access authorization. Zero-Knowledge Proofs (ZKPs) emerge as a solution to this challenge, providing a mechanism to verify user attributes for ABAC without disclosing those attributes on the blockchain, thereby maintaining privacy.

ZKPs have rapidly evolved from theoretical concepts to practical tools, revolutionizing several aspects of digital systems [1–3]. In the realm of data management, ZKPs have become instrumental in ensuring storage integrity. They allow verification of data authenticity and completeness without exposing sensitive information, a crucial capability for industries handling confidential records. In the financial sector, ZKPs are transforming digital asset transfers [4]. By enabling users to prove ownership and conduct transactions without revealing personal details or transaction amounts, ZKPs strike a balance between privacy and transparency in blockchain-based finance. Moreover, ZKPs are addressing one of the most pressing challenges in blockchain technology: scalability [5, 6]. By allowing complex computations to be performed off-chain and efficiently verified on-chain, ZKPs significantly reduce the computational load on blockchain networks. This breakthrough paves the way for increased transaction throughput without compromising security or decentralization. As ZKP technology continues to advance,

these applications in storage integrity [7], private digital asset transfers, and blockchain scalability are expected to drive significant innovations in secure and efficient digital systems.

The integration of ZKPs with blockchain technology has been the focus of numerous research initiatives. Among these, several systems have particular relevance to our work. One notable example is a study that explores the application of blockchain and Zero-Knowledge Succinct Non-Interactive Argument of Knowledge (ZK-SNARK) in adding privacy to a healthcare system for Internet of Things (IoT) [8]. This innovative approach leverages the inherent anonymity of blockchain to protect user privacy, while employing ZK-SNARK-based authentication mechanisms to prevent unauthorized access to sensitive medical data. The study [9] introduces a blockchain-based Access Control (AC) system for IoT that uses Zero-Knowledge Rollups (ZK-rollups) to address issues of low transaction speed and high latency in high-traffic environments. By batching AC authorization requests into a single zero-knowledge proof, the system enhances trustworthiness and efficiency. Experiments show that the system significantly reduces authorization time, particularly in high-traffic scenarios, while also preventing malicious behaviors.

The issue of this system alone is where should we store the data related to the access management, security policies, and user management, this issue is resolved by using a decentralized InterPlanetary File System (IPFS) which is designed for distributed peer-to-peer sharing which solve the centralization problem. IPFS offers a decentralized way of storing and sharing data, enhancing efficiency and speed by retrieving files from the nearest node. It resists censorship, reduces redundancy, and provides a more robust, version-controlled system for a persistent and resilient internet. This technology is particularly beneficial for decentralized applications, content distribution, and digital archiving [10]. We can communicate with this IPFS network by using Chainlink which connects existing systems to any public or private blockchain and enables

secure cross-chain communication, in this way we shift storing data on-chain to off-chain IPFS in secure way using Chainlink and provide better performance on Ethereum network [11].

### Proposed Model

The proposed model for a Zero-Knowledge Proof, Ethereum-Based Attribute-Based Access Control (ZK-ABAC) system, integrated with the Ethereum blockchain IPFS through Chainlink, presents a novel approach that provides efficient, transparent, and decentralized access control while preserving the privacy of user attributes. This model leverages traditional ABAC to ensure scalable access control, with the entire management and mechanism process executed by the Ethereum network via smart contracts, thereby imparting immutability to the system. All requisite data for the model is stored on the decentralized IPFS, and the entirety of communication between on-chain and off-chain components is governed by smart contracts.

Smart contract is the core element in the model since it controls the whole process, verifies the attributes provided by the users, grants/denies the access, and manages access policies and all other data related to IoT devices on IPFS [12]. Instead of attributes we use ZK-SNARK to verify the attributes without revealing them.

One of the innovative aspects of this model is the integration with Chainlink, a decentralized oracle network. This integration allows the smart contracts to interact with off-chain data sources and services securely and reliably. Specifically, attributes and device information, which are crucial for the ABAC system, are stored on IPFS servers. Chainlink oracles provide a bridge between these off-chain data stored on IPFS and the on-chain smart contracts on Ethereum. This ensures that the AC system can access up-to-date and accurate information about users and devices, which is essential for making correct access control decisions [13, 14].

Many research study different types of blockchain integrating with different types of access control [15–18]. However, no research addresses the privacy of users whose identities could potentially be revealed through the attributes (e.g., roles, positions, locations) used to gain access to resources. Our main contribution is applying ZKP to this system so we can assure privacy. The main focus is pointed at structuring the system and making ZKP integration its main core.

ZK-SNARK is a complex cryptographic construct. To understand how they could be used in conjunction with an ABAC system, it's important to delve into some technical aspects and equations that underpin ZK-SNARK. ZK-SNARK is built on a foundation of polynomial equations that are essential for their operation. These equations transform a computation, such as checking attributes for ABAC, into a set of equations within a finite field. A prevalent method for representing these polynomial equations is through Quadratic Arithmetic Programs (QAPs). QAPs play a crucial role in verifying the accurate execution of the ABAC policy check. Additionally, ZK-SNARK employs elliptic curve pairings which are instrumental for efficient proof generation and

verification. These pairings link the polynomial equations to cryptographic components, enhancing ZK-SNARK functionality.

There are three major steps for our proposed model.

**Step 1. System Setup.** In which we configure the system and initializing it to integrate the required technologies used in this mode which includes:

- **Defining ABAC Policies:** is the core of the access control mechanism, by defining the attributes that the ABAC model will process and deal with, also defining the policies that will manage the access control procedure. Those policies and object data is stored on IPFS;
- **Ethereum Smart Contracts:** is responsible for communicating with the users and the required objects, handling the ABAC checks, and managing data on IPFS servers. These contracts contain the logic to verify access based on user attributes;
- **ZK-SNARK Setup:** is about performing the trusted setup for ZK-SNARK to generate public parameters (proving and verification keys) and developing a ZK-SNARK circuits that can take user attributes and generate a proof without revealing the attributes themselves.

#### User Attribute Tokenization

**Step 2.** This step is about representing the attributes by tokens to be processed when the access is triggered and initializing the ZK-SNARK proofs which includes:

- **Issue Attribute Tokens:** Users receive tokens representing their attributes. These tokens are stored on Ethereum and can be verified by the smart contract;
- **ZK-SNARK Proof Generation:** Users generate ZK-SNARK proof that they possess tokens with the required attributes. This proof asserts the presence of attributes without revealing what they are.

**Step 3. Access Request.** This step is the actual process after setting up the environment, which includes:

- **Submit Access Request:** When a user wants to access a resource, they interact with the Ethereum smart contract. They submit their ZK-SNARK proof along with the access request;
- **Smart Contract Verifies Proof:** The smart contract uses the ZK-SNARK verification key to verify the proof. If the proof is valid, it confirms that the user has the necessary attributes;
- **Grant or Deny Access:** Based on the result of the ZK-SNARK proof verification, the smart contract grants or denies access to the resource.

This model is represented in Fig. 1.

Integrating technologies like ZK-SNARK, IPFS, and Chainlink with ABAC on Ethereum provides a distributed, efficient, and privacy-preserving access control mechanism.

### The Proposed Model Architecture

We will dive into details about configuring this model and integrating all the mentioned technologies together to draw the full image of the proposed model.

#### Define attributes

The first step to implement our model is to define the attributes and policies according to ZK-SNARK proofs.

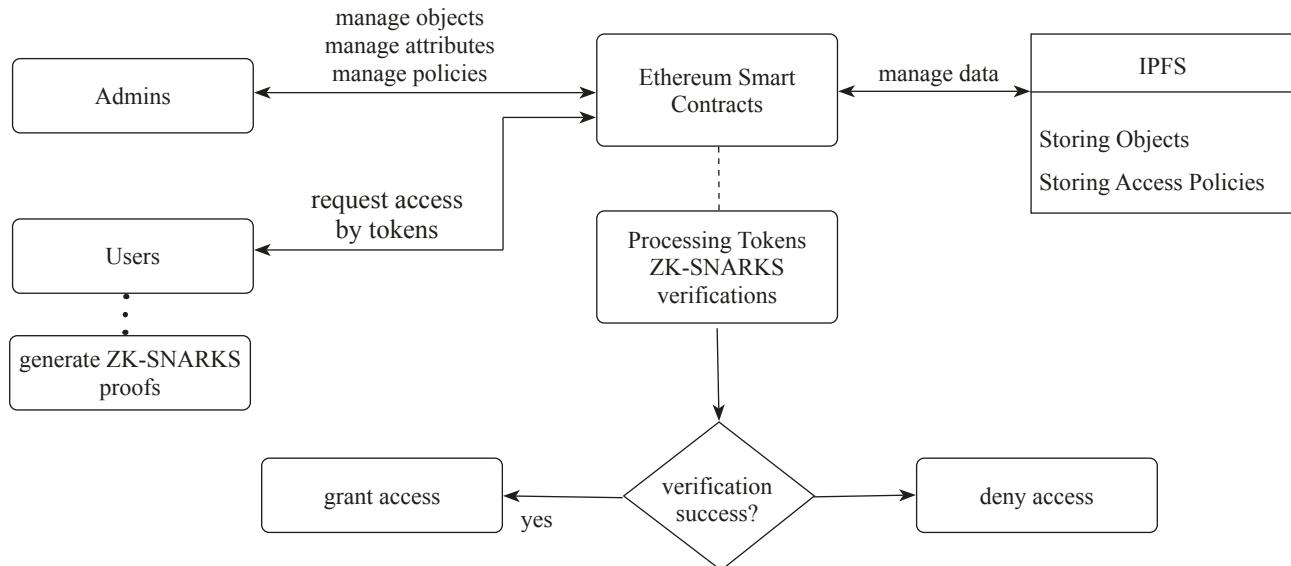


Fig. 1. System flow

Those policies should be presented as polynomial equations to be used in the ZK-SNARK setup phase.

Many studies discussed how to define attributes in a generic way that generalizes the nature of attributes that can apply and serve wide range of different systems [13, 19]. Attributes can be grouped, symbolized as  $A \in \{S, O, P, E\}$ , where  $A = \{\text{name: value}\}$ :

- $S$  signifies the subject attribute, which can be presented as an ID, profession... etc.
- $O$  pertains to the object attribute, which can be IP address, category, device...etc.
- $P$  relates to the permission attribute, like read, write, delete, or executing.
- $E$  is the environment attribute, like time, date, physical location... etc.

#### Represent Policies as Polynomial Equations

Having the attributes presented as set of variables:  $A \in \{S, O, P, E\}$ . Each variable can take multiple values based on the specific attribute it represents. For example,  $S_i$  for different roles,  $O_i$  for different objects, etc. Taking into consideration that the policy to access a certain object should be presented by one (or more) value for every attribute, the user request should be built using at least one value for each attribute type. Therefore, missing one attribute should make the access process invalid. Moreover, the policy can contain several values for the same attribute type. We should aim for a balance where the polynomials are complex enough to ensure security but not so complex that they become inefficient to compute. Therefore, we consider the access policy to be presented by set of quadratic polynomials, one polynomial for each attribute, and these can be combined to form the overall policy representation.

ZK-SNARK often uses QAPs to turn the check of validity of the access into a set of quadratic equations. QAPs can efficiently represent complex computations and are suitable for a wide range of ABAC policies.

Based on the previous, we propose the polynomial equation for the access policy to be built as follows:

- Each attribute type (Subject, Object, Permission, Environment) is represented by a set of possible values;
- Let  $A$  represents an attribute type (e.g., Subject), and  $A_i$  represents each possible value of  $A$ .

We propose generic equation for each attribute type as follows:

- For an attribute  $A$  requiring to be a specific single value  $A_k$

$$P_A = (A - A_k)^2;$$

- For an attribute  $A$  requiring multiple values  $A_1, A_2, \dots, A_n$  (AND operation)

$$P_A = \sum_{i=1}^n (A - A_i)^2;$$

- For an attribute  $A$  allowing any one of several values  $A_1, A_2, \dots, A_n$  (OR operation)

$$P_A = \prod_{i=1}^n (A - A_i).$$

Constructing a new access policy should be set of four attribute types (four quadratic equations) depending on the rule itself:

$$P_S + P_O + P_P + P_E = 0.$$

For example, let's consider a policy where Subjects  $S_1$  or  $S_3$  have Permissions  $P_1$  and  $P_2$  on Object  $O_1$  with Environment  $E_7$ . The polynomial equation representing this access policy should be constructed using quadratic equation for each attribute type as follows:

$$(S - S_1)(S - S_3) + (P - P_1)^2 + (P - P_2)^2 + (O - O_1)^2 + (E - E_7)^2 = 0.$$

Depending on the required access conditions, the admin can create a specific policy using the previous logic and link it to a specific object.

### ZK-SNARK Circuit Design and Setup

In the development of our ZK-SNARK system for ABAC policy verification, the circuit design is a crucial component. This circuit is meticulously engineered to assess the formulated polynomial equations that represent the ABAC policies. It operates by accepting user attributes as inputs and computing the corresponding polynomial value. The design ensures that if all specified attribute conditions within a policy are satisfied, the polynomial evaluation results in zero, signifying adherence to the policy. The system trusted setup is integral to its security architecture, involving the generation of essential cryptographic materials, specifically the proving key and the verification key, both of which are crucial to the ZK-SNARK framework.

The trusted setup procedure begins with the selection of cryptographic parameters, including appropriate elliptic curves and other foundational elements that underpin the security of the ZK-SNARK. In a secure environment, secret random values are then generated to create the proving and verification keys, ensuring true randomness in this critical step. The proving key, which is typically large, enables users to create proofs demonstrating compliance with ABAC policies without revealing their attributes. This key must be securely distributed to users. Simultaneously, the verification key generated using the same secret randomness allows the Ethereum smart contract to verify the proofs submitted by users. Unlike the proving key, the verification key is much smaller and is deployed within the Ethereum smart contract.

After generating the keys, the secret randomness used in their creation is securely and irreversibly destroyed to prevent the possibility of generating false proofs. The proving key is then distributed to users through secure channels, ensuring that every user who needs to generate proofs has access to it, while the verification key is embedded within the Ethereum smart contract responsible for verifying access requests. Secure record-keeping of the cryptographic parameters and keys (excluding the secret randomness) is maintained for system maintenance and

auditing purposes. Finally, the ZK-SNARK system is fully integrated with the policy management system, allowing for proofs to be generated based on the latest policies stored on IPFS and verified through Ethereum.

To summarize, ZK-SNARK is built on three main phases: Setup, Prove, and Verify:

- The Setup phase generates a pair of keys used by the prover and verifier.

$$\text{Setup}(\lambda) \rightarrow (p_k, v_k). \quad (1)$$

- The Prove phase takes the proving key, a statement to be proved (in terms of public inputs), and private inputs (known as the witness), and produces a proof  $\pi$ .

$$\text{Prove}(p_k, x, w) \rightarrow \pi. \quad (2)$$

- The Verify phase uses the verification key, the public inputs, and the proof to determine whether the proof is valid, i.e., whether it correctly demonstrates the truth of the statement without the verifier needing to know the private inputs.

$$\text{Verify}(v_k, x, \pi) \rightarrow \{0, 1\}, \quad (3)$$

where  $\lambda$  is the security parameter (indicating the size and strength of the cryptographic setup);  $p_k$  is the Proving Key which will be used by the prover;  $v_k$  is the Verification Key which will be used by the verifier;  $x$  represents the public inputs to the statement being proved;  $w$  is the witness or private inputs known only to the prover;  $\pi$  is the proof that the prover constructs, demonstrating that the inputs satisfy the statement without revealing the witness.

The output is a binary value, where 1 indicates that the proof is valid and 0 indicates that it is not.

After successfully generating the required key, we can represent ZK-SNARK circuit design by the next algorithm in Algorithm 1 — ZK-SNARK Proof Generation with Detailed Implicit Policy Equation.

```

1: procedure GenerateAccessProof(UserAttributes, ObjectID, IPFS_
Client, ProverKey, EthereumSC_Address)
2:     Fetch the policy for the requested object using ObjectID from IPFS.
3:     PolicyData ← IPFS_Client.Fetch(ObjectID)
4:     IsValidPolicy ← VerifyPolicyHash(PolicyData, EthereumSC_Address)
5:     if IsValidPolicy then
6:         ZK-SNARK_Proof ← ZK-SNARKProvingAlgorithm(UserAttributes,
ProverKey)
7:         AccessRequest ← package(ZK-SNARK_Proof, ObjectID)
8:         AccessGranted ← EthereumSC.VerifyProof(AccessRequest,
EthereumSC_Address)
9:         if AccessGranted then
10:             return Access token from Smart Contract
11:         else
12:             return Access denied
13:         end if
14:     else
15:         return Invalid policy data
16:     end if
17: end procedure

```

The algorithm for ZK-SNARK Proof Generation with Implicit Policy Equation is designed to enable a user to generate a zero-knowledge proof for accessing a specific object based on predefined access control policies. The algorithm operates within an environment where policies are stored on IPFS and verified through Ethereum, where:

- **UserAttributes**: The attributes of the user, such as their role, permissions, and other relevant details.
- **ObjectID**: The unique identifier of the object that the user wants to access.
- **IPFS\_Client**: A client interface to interact with IPFS for retrieving policy data.
- **ProverKey**: A cryptographic key obtained from the ZK-SNARK trusted setup phase, used for proof generation.
- **EthereumSC\_Address**: The address of the Ethereum Smart Contract used for verifying the proof.

#### Smart Contracts, IPFS, and Chainlink Oracle

In our paper we will focus only on the ZK-SNARK verification process for our model and not on the smart contracts or IPFS and Chainlink integrations. About Smart Contracts, there are many studies about it and it's been discussed in detail how many smart contracts needed and the structure of those contracts to facilitate the process [20, 21, 13]. Also we already conducted detailed research about that part in another article, including IPFS and Chainlink integrations [22].

The system employs a series of smart contracts to manage access control and data handling, leveraging the strengths of blockchain, IPFS, and Chainlink.

- **AccessRequestContract** handles user access requests by processing submitted attributes, retrieving relevant policies, and initiating the policy evaluation process.
- **AdminPolicyManager** allows administrators to manage policies, including adding, updating, viewing, and deleting them, ensuring that the system rules are up-to-date and properly enforced.
- **IoTDataManager** is responsible for managing the resources allowing for the registration, updating, and deletion of resources, as well as retrieving specific resource information.
- **PolicyEvaluator** plays a critical role by evaluating user attributes against the stored policies to grant or deny access based on compliance.
- **IPFSDataHandler** interfaces with the IPFS network to store and retrieve data, enhancing data availability and security through decentralized storage.
- **ChainlinkOracleAdapter** facilitates secure communication with off-chain data sources using Chainlink oracles, enabling the system to access external data reliably.

These smart contracts collectively create a robust and efficient access control system, ensuring secure, transparent, and decentralized management of resources and data. Therefore, this work is a continuation of our work regarding smart contracts and the other setups.

#### Experiments and results

The experiments and tests to evaluate the performance of our model have been conducted on a PC equipped with an Intel i7 processor (2.60 GHz) and 16 GB of RAM for

the prototype implementation. For the development of smart contracts, the Solidity language was used. These smart contracts were created using Solidity and deployed on the Goerli testnet, which serves as a testing platform for Ethereum smart contract development.

In our experiments, we utilized ZoKrates in conjunction with the Groth16 proving scheme to explore and validate the efficacy of implementing ZK-SNARK on the Ethereum blockchain [23–25]. ZoKrates provided a streamlined development environment enabling to define and compile privacy-preserving arithmetic circuits using its specialized domain-specific language. These circuits formed the backbone of our experimental setup, allowing us to generate zero-knowledge proofs efficiently. We then leveraged Groth16, renowned for its succinct proofs and efficient verification properties, to ensure the integrity and non-disclosure of sensitive computation data within our tests. This integration was crucial for demonstrating the potential of ZK-SNARK in enhancing privacy and scalability in blockchain applications.

We tested the functions presented in formulas (1)–(3). We measured the time cost of the three functions by building different circuits based on different number of users and calculated the required time for each function to complete off-chain, the result is shown in Table.

And the chart presenting the result is shown in Fig. 2.

#### Analysis of Results

- As the number of users increases, the time taken for both setup and proving phases increases significantly. This indicates that the computation and resource requirements scale with the number of users, which is expected since each user would require a unique proof.
- The setup time increases more dramatically than the proving time. For instance, between 100 and 10,000 users, setup time increases by over 90 times, while

Table. ZK-SNARK cost time by Number of Users

Number of Users	Setup	Prove	Verify
100	0.285	0.190	0.194
500	1.345	0.966	0.201
1,000	2.887	1.789	0.209
5,000	9.446	4.102	0.285
10,000	26.224	11.325	0.206

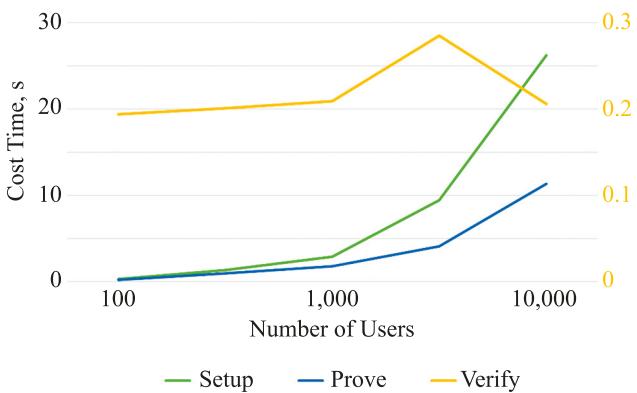


Fig. 2. Setup, Prove, and Verify cost time by number of users

proving time increases by about 60 times. This suggests that the initial parameter generation is highly resource-intensive and might become a bottleneck at scale.

- The verify phase does not scale in the same way as the setup and prove phases. The verification time remains relatively consistent and increases only marginally with the number of users. This is characteristic of ZK-SNARK, where verification is typically quick and does not significantly depend on the number of users.
- The fact that the verify phase times are small and stable is highly advantageous for scenarios where many independent verifications need to occur, such as on a blockchain network.

This experiment demonstrates the scalability challenges of ZK-SNARK in terms of setup and proving times. While verification remains fast regardless of the user count, the setup phase, in particular, may pose challenges for large-scale implementations due to its super-linear growth in time requirement. It's crucial for applications that utilize ZK-SNARK to consider these performance implications, especially for systems that require frequent setup or proving operations.

We also conducted an experiment about only the Verify process when executing it on Ethereum, we already did an experiment about smart contracts performance in general [22], and now we're testing the verification process on Goerli testnet. We adjusted the smart contract used for verification (PolicyEvaluator) to use ZoKrates for testing the time cost for the verification instead of the normal process described in [22], and the result is shown in Fig. 3.

#### Analysis of Results

- **ZK-SNARK Efficiency:** The orange line representing the verification time using ZK-SNARK is consistently below the blue line, which suggests that using ZK-SNARK for verification is more time-efficient than the traditional verification method.
- **Scalability:** As the number of requests increases, both methods show an increase in cost time. However, the increase in the time cost for the traditional verification method is more pronounced, which indicates that the verification with ZK-SNARK scales better with the number of requests.
- **Performance at Scale:** At lower numbers of requests (e.g., 10 to 100), the difference in verification time between the two methods is relatively small. However,

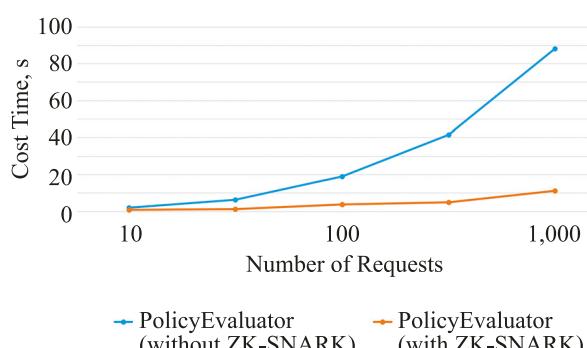


Fig. 3. Cost time for verification with ZK-SNARK and without ZK-SNARK

as the number of requests grows (e.g., from 500 to 1000), the difference becomes much more significant. This suggests that the benefits of ZK-SNARK become more apparent as the system is scaled up.

- **Goerli Testnet Context:** It's important to note that these tests were performed on the Goerli testnet which is an Ethereum test network. Real-world conditions on the Ethereum mainnet might lead to different performance characteristics due to network congestion and gas prices, although the relative performance between the two methods might be expected to remain consistent.

The use of ZK-SNARK (via ZoKrates) for the verification process in smart contracts significantly reduces the verification time, especially as the number of requests increases. This can lead to performance improvements in blockchain applications that require a large number of verifications. The lower time cost associated with ZK-SNARK verification can lead to more efficient smart contract operations, which can be particularly beneficial for applications with high throughput requirements.

All other tests related to the Smart Contracts in our work are included in the previously published paper [22].

## Conclusion

This paper presents a pioneering approach to Access Control in the realm of IoT and beyond, through the integration of ABAC with blockchain technology, ZK-SNARK, IPFS, and Chainlink oracles. Our proposed ZK-ABAC system represents a significant advancement in addressing the critical challenge of preserving user privacy while maintaining a robust, immutable, and transparent access control mechanism.

Our ZK-ABAC model innovatively combines the flexibility and efficiency of ABAC with the robustness and transparency of blockchain technology. By employing Ethereum smart contracts, the system ensures a decentralized and tamper-proof record of access control policies and transactions. The utilization of ZK-SNARK is pivotal in safeguarding user privacy; it enables users to prove their attribute-based access rights without revealing the actual attributes, thus maintaining confidentiality in every interaction, and the results show that the verification process is more efficient and less time consuming than the normal process and makes it suitable for on-chain applications.

Furthermore, the integration of the IPFS network facilitates a distributed storage solution, ensuring that access control policies are not only decentralized but also resilient and scalable. This feature is particularly crucial in addressing the concerns of centralized data management and single points of failure, which are common in traditional access control systems.

In conclusion, the ZK-ABAC model stands as a testament to the potential of combining blockchain technology, zero-knowledge proofs, distributed storage, and oracle networks to revolutionize access control systems. It paves the way for future research and development in this field, setting a new standard for privacy-preserving, decentralized access control in the digital age.

## References

- Goldwasser S., Micali S., Rackoff C. The knowledge complexity of interactive proof-systems. *Providing Sound Foundations for Cryptography: On the Work of Shafi Goldwasser and Silvio Micali*, 2019, pp. 203–225. <https://doi.org/10.1145/3335741.3335750>
- Chiesa A., Hu Y., Maller M., Mishra P., Vesely N., Ward N. Marlin: Preprocessing zkSNARKs with universal and updatable SRS. *Lecture Notes in Computer Science*, 2020, vol. 12105, pp. 738–768. [https://doi.org/10.1007/978-3-030-45721-1\\_26](https://doi.org/10.1007/978-3-030-45721-1_26)
- Campenelli M., Gailly N., Gennaro R., Jovanovic P., Mihali M., Thaler J. Linear time prover snarks with constant size proofs and square root size universal setup. *Lecture Notes in Computer Science*, 2023, vol. 14168, pp. 331–351. [https://doi.org/10.1007/978-3-031-44469-2\\_17](https://doi.org/10.1007/978-3-031-44469-2_17)
- Fuchsbauer G., Orrù M., Seurin Y. Aggregate cash systems: A cryptographic investigation of mimblewimble. *Lecture Notes in Computer Science*, 2019, vol. 11476, pp. 657–689. [https://doi.org/10.1007/978-3-030-17653-2\\_22](https://doi.org/10.1007/978-3-030-17653-2_22)
- Ozdemir A., Wahby R. Scaling verifiable computation using efficient set accumulators. *Proc. of the 29<sup>th</sup> USENIX Conference Security Symposium*, 2020, pp. 2075–2092.
- Xie T., Zhang J., Cheng Z., Zhang F., Zhang Y., Jia Y., Boneh D., Song D. zkbridge: Trustless cross-chain bridges made practical. *Proc. of the 2022 ACM SIGSAC Conference on Computer and Communications Security*, 2022, pp. 3003–3017. <https://doi.org/10.1145/3548606.3560652>
- Parno B., Howell J., Gentry C., Raykova M. Pinocchio: Nearly practical verifiable computation. *Communications of the ACM*, 2016, vol. 59, no. 2, pp. 103–112. <https://doi.org/10.1145/2856449>
- Luong D.A., Park J.H. Privacy-preserving blockchain-based healthcare system for IoT devices using ZK-SNARK. *IEEE Access*, 2022, vol. 10, pp. 55739–55752. <https://doi.org/10.1109/access.2022.3177211>
- Lin X., Zhang Y., Huang C., Xing B., Chen L., Hu D., Chen Y. An access control system based on blockchain with zero-knowledge rollups in high-traffic IoT environments. *Sensors*, 2023, vol. 23, no. 7, pp. 3443. <https://doi.org/10.3390/s23073443>
- Norvill R., Pontiveros B.B.F., State R., Cullen A. IPFS for reduction of chain size in Ethereum. *Proc. of the IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData)*, 2018, pp. 1121–1128. [https://doi.org/10.1109/cybermatics\\_2018.2018.00204](https://doi.org/10.1109/cybermatics_2018.2018.00204)
- Breidenbach L., Cachin C., Chan B., Coventry A., Ellis S., Juels A., Koushanfar F., Miller A., Magauran B., Moroz D., Nazarov S., Topliceanu A., Tramer F., Zhang F. *Chainlink 2.0: Next steps in the evolution of decentralized oracle networks*. Chainlink Labs, 2021, 136 p.
- Ouaddah A. A blockchain based access control framework for the security and privacy of IoT with strong anonymity unlinkability and intractability guarantees. *Advances in Computers*, 2019, vol. 115, pp. 211–258. <https://doi.org/10.1016/bs.adcom.2018.11.001>
- Figueroa S., Anorga J., Arrizabalaga S., Irigoyen I., Monterde M. An attribute-based access control using chaincode in RFID systems. *Proc. of the 10<sup>th</sup> IFIP International Conference on New Technologies, Mobility and Security (NTMS)*, 2019, pp. 1–5. <https://doi.org/10.1109/ntms.2019.8763824>
- Cruz J.P., Kaji Y., Yanai N. RBAC-SC: Role-based access control using smart contract. *IEEE Access*, 2018, vol. 6, pp. 12240–12251. <https://doi.org/10.1109/access.2018.2812844>
- Wang S., Zhang Y., Zhang Y. A blockchain-based framework for data sharing with fine-grained access control in decentralized storage systems. *IEEE Access*, 2018, vol. 6, pp. 38437–38450. <https://doi.org/10.1109/access.2018.2851611>
- Khan F., Li H., Zhang L., Shen J. An expressive hidden access policy CP-ABE. *Proc. of the IEEE Second International Conference on Data Science in Cyberspace (DSC)*, 2017, pp. 178–186. <https://doi.org/10.1109/dsc.2017.29>
- Xu R., Chen Y., Blasch E., Chen G. BlendCAC: A smart contract enabled decentralized capability-based access control mechanism for the IoT. *Computers*, 2018, vol. 7, no. 3, pp. 39. <https://doi.org/10.3390/computers7030039>
- Nishide T., Yoneyama K., Ohta K. Attribute-based encryption with partially hidden encryptor-specified access structures. *Lecture Notes in Computer Science*, 2008, vol. 5037, pp. 111–129. [https://doi.org/10.1007/978-3-540-68914-0\\_7](https://doi.org/10.1007/978-3-540-68914-0_7)

## Литература

- Goldwasser S., Micali S., Rackoff C. The knowledge complexity of interactive proof-systems // *Providing Sound Foundations for Cryptography: On the Work of Shafi Goldwasser and Silvio Micali*. 2019. P. 203–225. <https://doi.org/10.1145/3335741.3335750>
- Chiesa A., Hu Y., Maller M., Mishra P., Vesely N., Ward N. Marlin: Preprocessing zkSNARKs with universal and updatable SRS // *Lecture Notes in Computer Science*. 2020. V. 12105. P. 738–768. [https://doi.org/10.1007/978-3-030-45721-1\\_26](https://doi.org/10.1007/978-3-030-45721-1_26)
- Campenelli M., Gailly N., Gennaro R., Jovanovic P., Mihali M., Thaler J. Linear time prover snarks with constant size proofs and square root size universal setup // *Lecture Notes in Computer Science*. 2023. V. 14168. P. 331–351. [https://doi.org/10.1007/978-3-031-44469-2\\_17](https://doi.org/10.1007/978-3-031-44469-2_17)
- Fuchsbauer G., Orrù M., Seurin Y. Aggregate cash systems: A cryptographic investigation of mimblewimble // *Lecture Notes in Computer Science*. 2019. V. 11476. P. 657–689. [https://doi.org/10.1007/978-3-030-17653-2\\_22](https://doi.org/10.1007/978-3-030-17653-2_22)
- Ozdemir A., Wahby R. Scaling verifiable computation using efficient set accumulators // *Proc. of the 29<sup>th</sup> USENIX Conference Security Symposium*. 2020. P. 2075–2092.
- Xie T., Zhang J., Cheng Z., Zhang F., Zhang Y., Jia Y., Boneh D., Song D. zkbridge: Trustless cross-chain bridges made practical // *Proc. of the 2022 ACM SIGSAC Conference on Computer and Communications Security*. 2022. P. 3003–3017. <https://doi.org/10.1145/3548606.3560652>
- Parno B., Howell J., Gentry C., Raykova M. Pinocchio: Nearly practical verifiable computation // *Communications of the ACM*. 2016. V. 59, N. 2. P. 103–112. <https://doi.org/10.1145/2856449>
- Luong D.A., Park J.H. Privacy-preserving blockchain-based healthcare system for IoT devices using ZK-SNARK // *IEEE Access*. 2022. V. 10. P. 55739–55752. <https://doi.org/10.1109/access.2022.3177211>
- Lin X., Zhang Y., Huang C., Xing B., Chen L., Hu D., Chen Y. An access control system based on blockchain with zero-knowledge rollups in high-traffic IoT environments // *Sensors*. 2023. V. 23, N. 7. P. 3443. <https://doi.org/10.3390/s23073443>
- Norvill R., Pontiveros B.B.F., State R., Cullen A. IPFS for reduction of chain size in Ethereum // *Proc. of the IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData)*. 2018. P. 1121–1128. [https://doi.org/10.1109/cybermatics\\_2018.2018.00204](https://doi.org/10.1109/cybermatics_2018.2018.00204)
- Breidenbach L., Cachin C., Chan B., Coventry A., Ellis S., Juels A., Koushanfar F., Miller A., Magauran B., Moroz D., Nazarov S., Topliceanu A., Tramer F., Zhang F. Chainlink 2.0: Next steps in the evolution of decentralized oracle networks. Chainlink Labs, 2021, 136 p.
- Ouaddah A. A blockchain based access control framework for the security and privacy of IoT with strong anonymity unlinkability and intractability guarantees // *Advances in Computers*. 2019. V. 115. P. 211–258. <https://doi.org/10.1016/bs.adcom.2018.11.001>
- Figueroa S., Anorga J., Arrizabalaga S., Irigoyen I., Monterde M. An attribute-based access control using chaincode in RFID systems // *Proc. of the 10<sup>th</sup> IFIP International Conference on New Technologies, Mobility and Security (NTMS)*. 2019. P. 1–5. <https://doi.org/10.1109/ntms.2019.8763824>
- Cruz J.P., Kaji Y., Yanai N. RBAC-SC: Role-based access control using smart contract // *IEEE Access*. 2018. V. 6. P. 12240–12251. <https://doi.org/10.1109/access.2018.2812844>
- Wang S., Zhang Y., Zhang Y. A blockchain-based framework for data sharing with fine-grained access control in decentralized storage systems // *IEEE Access*. 2018. V. 6. P. 38437–38450. <https://doi.org/10.1109/access.2018.2851611>
- Khan F., Li H., Zhang L., Shen J. An expressive hidden access policy CP-ABE // *Proc. of the IEEE Second International Conference on Data Science in Cyberspace (DSC)*. 2017. P. 178–186. <https://doi.org/10.1109/dsc.2017.29>
- Xu R., Chen Y., Blasch E., Chen G. BlendCAC: A smart contract enabled decentralized capability-based access control mechanism for the IoT // *Computers*. 2018. V. 7, N. 3. P. 39. <https://doi.org/10.3390/computers7030039>
- Nishide T., Yoneyama K., Ohta K. Attribute-based encryption with partially hidden encryptor-specified access structures // *Lecture Notes in Computer Science*. 2008. V. 5037. P. 111–129. [https://doi.org/10.1007/978-3-540-68914-0\\_7](https://doi.org/10.1007/978-3-540-68914-0_7)

19. Liu H., Han D., Li D. Fabric-IoT: A blockchain-based access control system in IoT. *IEEE Access*, 2020, vol. 8, pp. 18207–18218. <https://doi.org/10.1109/access.2020.2968492>
20. Ding S., Cao J., Li C., Fan K., Li H. A novel attribute-based access control scheme using blockchain for IoT. *IEEE Access*, 2019, vol. 7, pp. 38431–38441. <https://doi.org/10.1109/access.2019.2905846>
21. Zhou Z., Huang D., Wang Z. Efficient privacy-preserving ciphertext-policy attribute based-encryption and broadcast encryption. *IEEE Transactions on Computers*, 2015, vol. 64, no. 1, pp. 126–138. <https://doi.org/10.1109/tc.2013.200>
22. Maalla M.A., Bezzateev S.V. An Ethereum based attribute-based access control for IoT. *Proceedings of the Institute for Systems Analysis Russian Academy of Sciences (ISA RAS)*, 2024, vol. 74, no. 1, pp. 29–34. <https://doi.org/10.14357/20790279240104>
23. Eberhardt J., Tai S. ZoKrates - scalable privacy-preserving off-chain computations. *Proc. of the IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData)*, 2018, pp. 1084–1091. [https://doi.org/10.1109/cybermatics\\_2018.2018.00199](https://doi.org/10.1109/cybermatics_2018.2018.00199)
24. Baghery K., Pindado Z., Ràfols C. Simulation extractable versions of Groth's ZK-SNARK revisited. *Lecture Notes in Computer Science*, 2020, vol. 12579, pp. 453–461. [https://doi.org/10.1007/978-3-030-65411-5\\_22](https://doi.org/10.1007/978-3-030-65411-5_22)
25. Baghery K., Kohlweiss M., Siim J., Volkov M. Another look at extraction and randomization of Groth's ZK-SNARK. *Lecture Notes in Computer Science*, 2021, pp. 457–475. [https://doi.org/10.1007/978-3-662-64322-8\\_22](https://doi.org/10.1007/978-3-662-64322-8_22)
19. Liu H., Han D., Li D. Fabric-IoT: A blockchain-based access control system in IoT // IEEE Access. 2020. V. 8. P. 18207–18218. <https://doi.org/10.1109/access.2020.2968492>
20. Ding S., Cao J., Li C., Fan K., Li H. A novel attribute-based access control scheme using blockchain for IoT // IEEE Access. 2019. V. 7. P. 38431–38441. <https://doi.org/10.1109/access.2019.2905846>
21. Zhou Z., Huang D., Wang Z. Efficient privacy-preserving ciphertext-policy attribute based-encryption and broadcast encryption // IEEE Transactions on Computers. 2015. V. 64. N 1. P. 126–138. <https://doi.org/10.1109/tc.2013.200>
22. Maalla M.A., Bezzateev S.V. An Ethereum based attribute-based access control for IoT // Труды ИСА РАН. 2024. Т. 74. № 1. С. 29–34. <https://doi.org/10.14357/20790279240104>
23. Eberhardt J., Tai S. ZoKrates - scalable privacy-preserving off-chain computations // Proc. of the IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData). 2018. P. 1084–1091. [https://doi.org/10.1109/cybermatics\\_2018.2018.00199](https://doi.org/10.1109/cybermatics_2018.2018.00199)
24. Baghery K., Pindado Z., Ràfols C. Simulation extractable versions of Groth's ZK-SNARK revisited // Lecture Notes in Computer Science. 2020. V. 12579. P. 453–461. [https://doi.org/10.1007/978-3-030-65411-5\\_22](https://doi.org/10.1007/978-3-030-65411-5_22)
25. Baghery K., Kohlweiss M., Siim J., Volkov M. Another look at extraction and randomization of Groth's ZK-SNARK // Lecture Notes in Computer Science. 2021. P. 457–475. [https://doi.org/10.1007/978-3-662-64322-8\\_22](https://doi.org/10.1007/978-3-662-64322-8_22)

## Authors

- Maher Maalla** — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-4806-8608>, maher.malla7@gmail.com
- Sergey V. Bezzateev** — D.Sc., Professor, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation; Head of Department, Saint Petersburg State University of Aerospace Instrumentation, Saint Petersburg, 190000, Russian Federation, <https://orcid.org/0000-0002-0924-6221>, bsv@guap.ru

## Авторы

- Маалла Махер** — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-4806-8608>, maher.malla7@gmail.com
- Беззатеев Сергей Валентинович** — доктор технических наук, доцент, профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация; заведующий кафедрой, Санкт-Петербургский государственный университет аэрокосмического приборостроения, Санкт-Петербург, 190000, Российская Федерация, <https://orcid.org/0000-0002-0924-6221>, bsv@guap.ru

Received 06.05.2024

Approved after reviewing 15.08.2024

Accepted 16.09.2024

Статья поступила в редакцию 06.05.2024

Одобрена после рецензирования 15.08.2024

Принята к печати 16.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-806-814

УДК 004.032.26, 004.932.72'

## Сравнительный анализ нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам

Андрей Витальевич Мельников<sup>1</sup>, Юрий Михайлович Полищук<sup>2</sup>,  
Михаил Александрович Рusanov<sup>3</sup>✉, Валерьян Ринатович Аббазов<sup>4</sup>,  
Глеб Александрович Кочергин<sup>5</sup>, Матвей Андреевич Куприянов<sup>6</sup>,  
Оксана Ахметсафаевна Байсалямова<sup>7</sup>, Олег Игоревич Соколков<sup>8</sup>

<sup>1,2,3,4,5,6,7,8</sup> Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск,  
628011, Российская Федерация

<sup>1,3,5</sup> Югорский государственный университет, Ханты-Мансийск, 628011, Российская Федерация

<sup>1</sup> melnikovav@uriit.ru, <https://orcid.org/0000-0002-1073-7108>

<sup>2</sup> polichukjm@uriit.ru, <https://orcid.org/0000-0002-4944-4919>

<sup>3</sup> rusanovma@uriit.ru✉, <https://orcid.org/0000-0002-9926-4609>

<sup>4</sup> abbazovvr@uriit.ru, <https://orcid.org/0009-0008-9315-2041>

<sup>5</sup> kocherginga@uriit.ru, <https://orcid.org/0009-0001-4875-7489>

<sup>6</sup> kupriyanovma@uriit.ru, <https://orcid.org/0000-0002-9476-2887>

<sup>7</sup> baysalyamova@uriit.ru, <https://orcid.org/0009-0000-0633-3832>

<sup>8</sup> sokolkovo@uriit.ru, <https://orcid.org/0009-0006-5869-1395>

### Аннотация

**Введение.** Исследована задача повышения оперативности обнаружения и картографирования лесных рубок по космическим снимкам с целью выявления нарушений экологического законодательства. Традиционные методы дешифрирования данных дистанционного зондирования Земли требуют больших трудозатрат и высокой квалификации исполнителей. Для автоматизации процессов дешифрирования космических снимков разработано большое количество разнообразных методов, в том числе основанных на применении современных технологий глубокого машинного обучения. В работе проведен сравнительный анализ сверточных и трансформерных моделей нейронных сетей, перспективных для решения задач сегментации лесных рубок по летним космическим снимкам со спутника Sentinel-2. **Метод.** В проведенном исследовании для сегментации лесных рубок применялись сверточные модели U-Net++, MA-Net, 3D U-Net, FPN-ConvLSTM и трансформерные модели SegFormer, Swin-UperNet. Особенностью компьютерного эксперимента является адаптация различных моделей нейронных сетей для анализа пары разновременных многоканальных спутниковых изображений. Представлено описание исходных данных, процедура их предобработки с учетом специфики и методика формирования обучающей выборки на основе имеющегося архива космических снимков. Предложены процедуры обучения и оценки точности рассматриваемых нейросетевых моделей с использованием метрики F1. Для оценки точности выполнено сравнение результатов моделирования с традиционным методом визуального дешифрирования с применением средств геоинформационных систем. **Основные результаты.** Получены результаты компьютерного эксперимента на примере территории Ханты-Мансийского автономного округа. Сравнение моделей сегментации лесных рубок по летним космическим снимкам показало, что точность F1 для разных моделей находится в пределах от 0,409 до 0,767. Наибольшую точность показала трансформерная модель SegFormer, которая позволила обнаруживать лесные рубки, неучтенные человеком. Время обработки одной пары полноразмерных космических снимков площади размером  $100 \times 100 \text{ км}^2$  составило 15 мин, что в 16 раз меньше времени, требуемого специалисту для выполнения той же задачи традиционным способом. Такая скорость обработки снимков является важным показателем для мониторинга обширных лесохозяйственных территорий. **Обсуждение.** Предлагаемый метод сегментации лесных рубок, основанный на трансформерной нейронной сети SegFormer, может быть использован для решения задачи оперативного выявления и картографирования незаконных лесных рубок. Для повышения качества работы модели необходима балансировка обучающей выборки с целью

© Мельников А.В., Полищук Ю.М., Рusanov M.А., Аббазов В.Р., Кочергин Г.А., Куприянов М.А., Байсалямова О.А.,  
Соколов О.И., 2024

выравнивания количества снимков с полигонами рубок различной формы и размера, а также включение в выборку снимков с частичной облачностью и тенями от облаков.

#### Ключевые слова

картирование лесных рубок, космические снимки, глубокое машинное обучение, нейросетевые модели, сегментация изображений, мониторинг лесных территорий

**Ссылка для цитирования:** Мельников А.В., Полищук Ю.М., Русанов М.А., Аббазов В.Р., Кочергин Г.А., Куприянов М.А., Байсалямова О.А., Соколов О.И. Сравнительный анализ нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 806–814. doi: 10.17586/2226-1494-2024-24-5-806-814

## Comparative analysis of neural network models for felling mapping in summer satellite imagery

Andrey V. Melnikov<sup>1</sup>, Yuri M. Polishchuk<sup>2</sup>, Mikhail A. Rusanov<sup>3</sup>✉, Valerian R. Abbazov<sup>4</sup>, Gleb A. Kochergin<sup>5</sup>, Matvey A. Kupriyanov<sup>6</sup>, Oksana A. Baisalyamova<sup>7</sup>, Oleg I. Sokolkov<sup>8</sup>

<sup>1,2,3,4,5,6,7,8</sup> Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation

<sup>1,3,5</sup> Yugra State University, Khanty-Mansiysk, 628011, Russian Federation

<sup>1</sup> melnikovav@uriit.ru, <https://orcid.org/0000-0002-1073-7108>

<sup>2</sup> polichukjm@uriit.ru, <https://orcid.org/0000-0002-4944-4919>

<sup>3</sup> rusanovma@uriit.ru✉, <https://orcid.org/0000-0002-9926-4609>

<sup>4</sup> abbazovvr@uriit.ru, <https://orcid.org/0009-0008-9315-2041>

<sup>5</sup> kocherginga@uriit.ru, <https://orcid.org/0009-0001-4875-7489>

<sup>6</sup> kupriyanovma@uriit.ru, <https://orcid.org/0000-0002-9476-2887>

<sup>7</sup> baysalyamovaoa@uriit.ru, <https://orcid.org/0009-0000-0633-3832>

<sup>8</sup> sokolkovo@uriit.ru, <https://orcid.org/0009-0006-5869-1395>

#### Abstract

The study aimed to improve the efficiency of detecting and mapping felling using satellite imagery, in order to identify violations of environmental regulations. Traditional remote sensing data interpretation methods are labor-intensive and require high operator expertise. To automate the satellite image interpretation process, numerous approaches have been developed, including those leveraging advanced deep machine learning technologies. The presented work conducted a comparative analysis of convolutional and transformer neural network models for the segmentation of felling in summer Sentinel-2 satellite imagery. The convolutional models evaluated included U-Net++, MA-Net, 3D U-Net, and FPN-ConvLSTM, while the transformer models were SegFormer and Swin-UpperNet. A key aspect was the adaptation of these models to analyze pairs of multi-temporal, multi-channel satellite images. The data preprocessing, training sample generation, and model training and evaluation procedures using the F1 metric are described. The modeling results were compared to traditional visual interpretation methods using GIS tools. Experiments on the territory of the Khanty-Mansiysk Autonomous Okrug showed that the F1 accuracy of the different models ranged from 0.409 to 0.767, with the SegFormer transformer model achieving the highest performance and detecting felling missed by human interpretation. The processing time for a  $100 \times 100 \text{ km}^2$  image pair was 15 minutes, 16 times faster than manual methods — an important factor for large-scale forest monitoring. The proposed SegFormer-based felling segmentation approach can be used for rapid detection and mapping of illegal logging. Further improvements could involve balancing the training dataset to include more diverse clearing shapes and sizes as well as incorporating partially cloudy images.

#### Keyword

felling mapping, satellite imagery, deep machine learning, neural network models, image segmentation, forest area monitoring

**For citation:** Melnikov A.V., Polishchuk Yu.M., Rusanov M.A., Abbazov V.R., Kochergin G.A., Kupriyanov M.A., Baisalyamova O.A., Sokolkov O.I. Comparative analysis of neural network models for felling mapping in summer satellite imagery. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 806–814 (in Russian). doi: 10.17586/2226-1494-2024-24-5-806-814

## Введение

Активное освоение территорий северных регионов России, связанное с разведкой, добычей и транспортировкой углеводородного сырья и других полезных ископаемых, приводит к необходимости вырубки лесных насаждений с целью обустройства объектов обрабатывающей и транспортной инфраструктуры ресурсодобывающих предприятий. В связи с этим приоритетными направлениями в сфере охраны окружающей среды и природных ресурсов регионов являются мониторинг

лесных экосистем и задачи устойчивого управления лесным фондом региона, включая контроль несанкционированных лесных рубок.

Особую важность решения этих задач приобретает Ханты-Мансийский автономный округ (ХМАО), на территории которого функционирует Западно-Сибирский нефтедобывающий комплекс мирового уровня, поставляющий почти половину российской нефти. Большая часть территории округа, занимающего площадь 530 тыс.  $\text{km}^2$ , покрыто лесной растительностью, на состояние которой заметное воздействие

оказывает нефтедобыча. Кроме того, в ХМАО ведется интенсивная лесозаготовка, в результате которой вырубке подвергаются довольно обширные территории лесного фонда.

С целью контроля за вырубкой лесных насаждений на территории ХМАО с 2014 г. ведется непрерывный космический мониторинг территории лесного фонда, направленный в том числе и на оперативное выявление незаконных лесных рубок. В результате этой работы была создана база данных «Реестр изменений лесного фонда ХМАО» [1], которая содержит более 15 тыс. записей, включающих информацию о выявленных лесных рубках. Наполнение указанной базы данных осуществлялось с использованием разновременных космических снимков, дешифрирование которых проводилось традиционными методами с применением средств геоинформационной системы QGIS.

Однако эффективность традиционного подхода к выявлению лесных рубок по космическим снимкам, требующего привлечения квалифицированных специалистов для их дешифрирования, ввиду трудоемкости и высоких затрат времени оказывается относительно невысокой. По этой причине, актуальной является задача автоматизации процесса выявления лесных рубок на основе дешифрирования спутниковых изображений. Наиболее перспективными в решении этой задачи рассматриваются методы, основанные на использовании нейронных сетей для обнаружения изменений на лесных участках по космическим снимкам.

### Обзор методов сегментации изображений

В [2–4] рассмотрены вопросы применения нейронных сетей для автоматизации процесса дешифрирования спутниковых изображений в задачах обнаружения изменений в состоянии лесных территорий. Отметим, что данные научные работы посвящены выявлению изменений состояния лесного фонда на территории экваториальных лесов. Учитывая особенности лесных насаждений в северных регионах России, и особенно, в Сибири, где распространены таежные леса boreального пояса с преобладанием хвойных пород деревьев, рассмотренные в [2–4], методы оперативного выявления лесных рубок по космическим снимкам на основе нейронных сетей, разработанные для экваториальных лесов, не применимы для решения поставленной в работе задачи.

В настоящее время известны единичные работы [5–7], в которых рассматриваются вопросы применения нейросетевых моделей для определения лесных рубок на северных территориях России по космическим снимкам. В [5] рассмотрено использование методов глубокого обучения для идентификации повреждений леса, в том числе и лесных рубок, на европейской территории России и Урала с использованием пар разновременных снимков Sentinel-2. На основе сравнения нескольких моделей, имеющих архитектуру U-Net, в [6] показано, что модель MobilNetv2 U-Net продемонстрировала наилучшую точность в сегментации лесных рубок на территории Иркутской области. В [6] также описано применение сверточной нейронной сети ResNet50

для определения рубок с использованием космических снимков Sentinel-2. Однако точность выявления рубок оказалась невысокой.

В [7] исследована нейросетевая модель обнаружения рубок на территории ХМАО распространенной архитектуры U-Net++, которая показала высокую эффективность при использовании зимних космических снимков Sentinel-2. По причине значительной доли лесных вырубок на территории ХМАО, которые производятся в летний период, для повышения оперативности выявления таких рубок целесообразно использование летних снимков. Отметим, что выполненный в рамках настоящей работы предварительный анализ применения модели U-Net++ показал ее крайне низкую точность в задачах выявления рубок на территории ХМАО по летним снимкам.

Исходя из этого, возникает необходимость проведения сравнительного анализа известных методов машинного обучения с целью выбора нейросетевой модели, позволяющей наиболее эффективно выделять лесные рубки по паре разновременных космических снимков летнего периода на северных территориях. В результате целью работы является проведение сравнительного анализа известных нейросетевых моделей, пригодных для выявления лесных рубок по космическим снимкам, для определения архитектуры нейросетевой модели, обеспечивающей наиболее высокую точность обнаружения лесных рубок по оптическим снимкам Sentinel-2, полученным в летний период, на примере лесной территории ХМАО.

### Исходные данные и методы

В качестве исходных данных для формирования обучающей выборки и тестирования различных нейросетевых моделей были использованы космические снимки со спутника Sentinel-2<sup>1</sup>, обработанные до уровня 2, где каждый снимок представляет собой орто-трансформированное многоканальное изображение с атмосферной коррекцией [8]. Для обучения моделей выбраны снимки, которые имеют изображение поверхности Земли, полученные из 10 каналов с пространственным разрешением 10 и 20 м.

В настоящее время разработано и успешно применяется для сегментации изображений, в том числе и многоканальных космических снимков, достаточно большое количество различных архитектур нейронных сетей. Анализ наиболее популярных нейронных сетей показал, что в зависимости от особенностей архитектуры они могут быть сгруппированы в два класса: сверточные и трансформерные.

Сверточные нейронные сети являются особым типом искусственных нейронных сетей, которые традиционно используются для анализа данных с пространственной или временной структурой, таких как изображения, звук или видео. К этому классу, напри-

<sup>1</sup> Официальный сайт Sentinel Online [Электронный ресурс]. Режим доступа: [sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/processing-levels/level-2](https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/processing-levels/level-2), свободный. Яз. англ. (дата обращения: 28.06.2024).

мер, относятся следующие исследуемые авторами сети: U-Net++ [9, 10], MA-Net [11], 3D U-Net [9, 10], FPN-ConvLSTM [9, 12, 13], которые показали свою эффективность во многих задачах компьютерного зрения, включая классификацию изображений, детектирование объектов, сегментацию и многое другое. Основной элемент сверточной нейронной сети — сверточный слой, который применяет фильтры (ядра свертки) к входным данным. Фильтры позволяют извлекать важные признаки изображения объектов, такие как границы, формы или текстуры, сохраняя при этом пространственную информацию. За каждым сверточным слоем следует специальный слой, который уменьшает размерность данных и способствует выявлению более обобщенных и инвариантных признаков.

Трансформерные нейронные сети имеют архитектуру, адаптированную для обработки последовательностей данных, таких как тексты, аудиозаписи или временные ряды. К этому классу, например, относятся две нейронные сети, исследуемые в настоящей работе: SegFormer [14] и Swin-UperNet [15]. Главная отличительная особенность трансформерных нейронных сетей — использование механизма внимания, основная идея которого заключается в том, что трансформер обрабатывает не всю последовательность входных данных, а выявляет связи между наиболее релевантными объектами входной последовательности. Это позволяет модели распознать контекст и взаимосвязи на разных уровнях и создать более глубокие связи между элементами последовательности. Хотя трансформерные нейронные сети были разработаны в основном для обработки текстовых данных, существуют различные модификации архитектуры этих нейронных сетей, специально предназначенные для анализа и сегментации изображений.

## Результаты и обсуждение

Общая схема формирования набора обучающих данных, состоящего из экспериментальных данных о лесных рубках (совокупности кадров, полученных из космических снимков) и размеченных данных (совокупности масок контуров лесных рубок для каждого кадра), для разработки модели представлена в [7]. В качестве источника информации для обучения нейронной сети использовалась база данных выявленных лесных рубок на территории ХМАО [1]. Для каждой известной лесной рубки выбиралась пара разновременных космических снимков (до и после рубки), представляющих собой ортотрансформированные изображения с атмосферной коррекцией 10 спектральных каналов с разрешением 10 и 20 м.

Далее изображения со всех спектральных каналов с разрешением 20 м с использованием нейросетевой модели DeepSentinel-2 [16] преобразовывались в изображения с пространственным разрешением 10 м. На следующем шаге формировались 20-канальные растровые изображения, которые впоследствии разрезались на кадры размером 256 × 256 пикселов. Таким образом, каждый сформированный кадр содержал в себе информацию о территории лесного участка до рубки и после

нее. Пример 20-канального кадра из набора обучающих данных (20-канальных изображений) представлен на рис. 1, где изображения 1–10 представляют собой спектральные каналы космического снимка, выполненного до рубки, изображения 11–20 — после рубки, изображение 21 — маска контуров лесных рубок для данной пары космических снимков.

В настоящей работе использованы модели нейронных сетей, которые принимают на вход или единичное, или последовательность RGB-изображений. При этом выполнен анализ космических снимков, представляющих 20-канальные изображения, поэтому возникла необходимость в адаптации блока входных данных для этих моделей. Это позволило обеспечить возможность обработки многоканальных снимков указанной размерности нейросетевыми архитектурами, изначально предназначенными для работы с трехканальными RGB-изображениями.

Границы векторных контуров известных лесных рубок из базы данных [1] конвертировались в растровый формат данных и далее также разрезались на кадры размером 256 × 256 пикселов соответственно 20-канальным кадрам космических снимков. Пример изображения маски контуров лесных рубок для 20-канального кадра представлен на рис. 1 (изображение 21).

Для подготовки набора обучающих данных использовано более 2700 пар разновременных космических снимков за летний период 2017–2022 гг., из которых было сформировано более 43 000 кадров размером 256 × 256 пикселов. Полученный набор кадров разделен на обучающую, валидационную и тестовую выборки, объемы которых составили 40 000, 1000 и 2000 кадров соответственно.

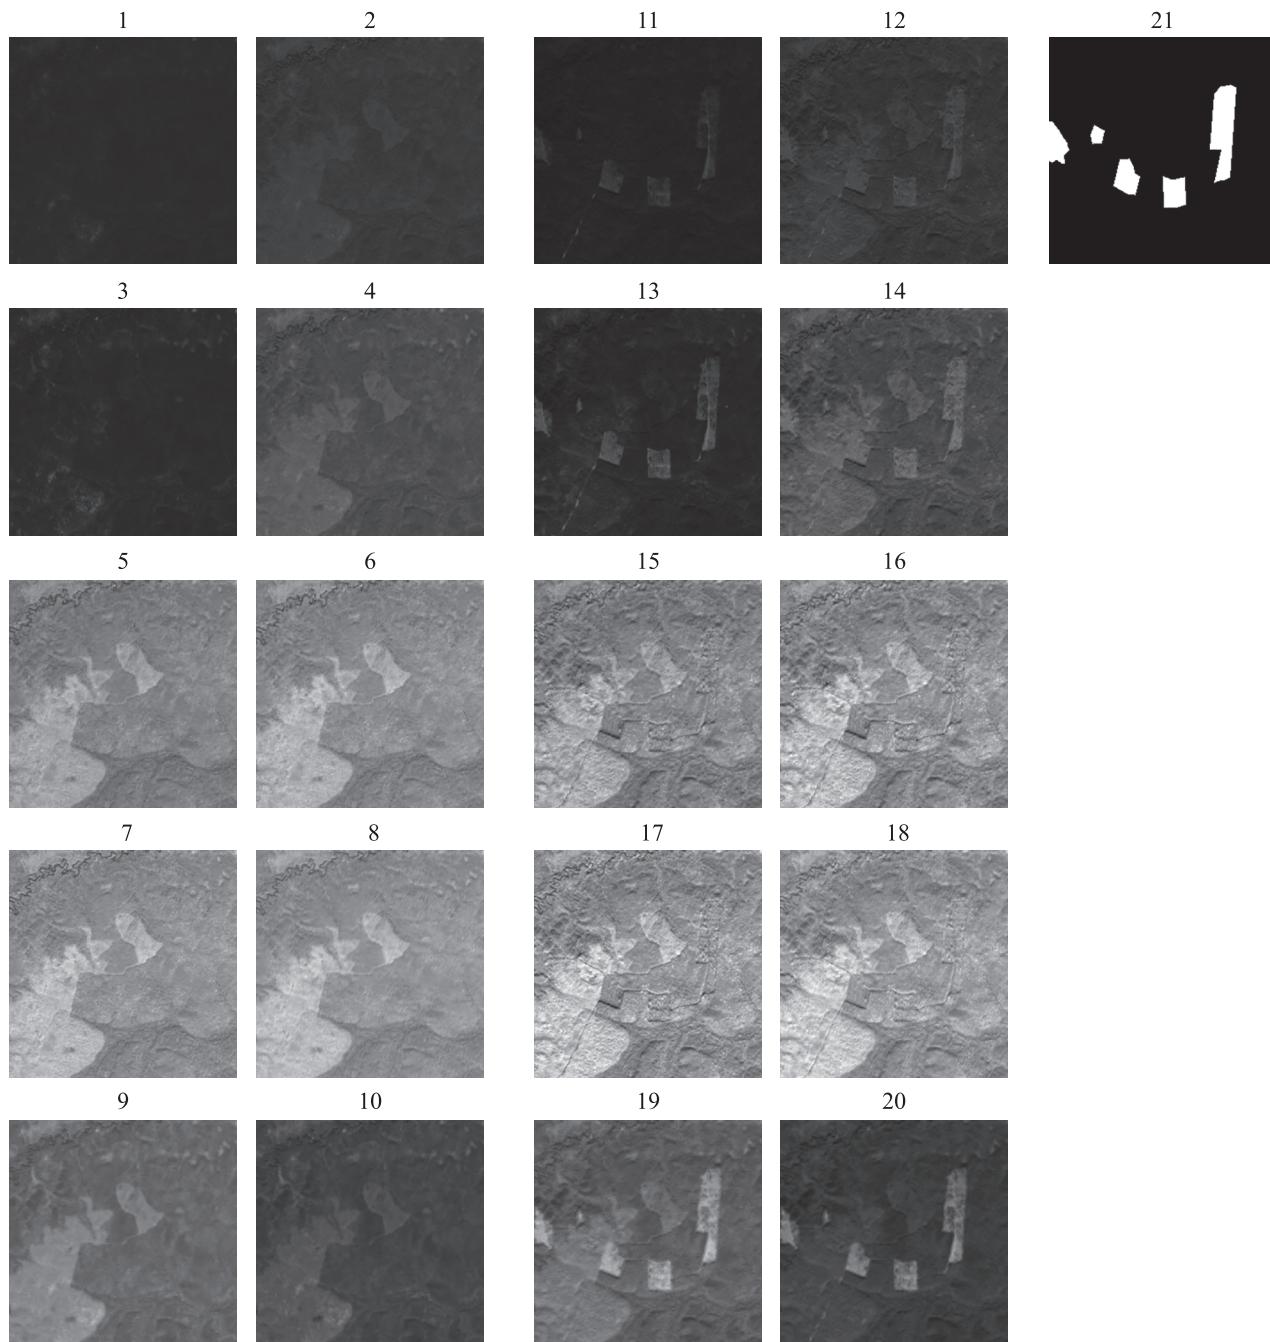
Обучающая выборка — набор кадров, используемый для настройки параметров модели. Эта выборка предоставляет модели информацию о различных входных данных и соответствующих им правильных ответах. Нейронная сеть обрабатывает обучающие примеры и корректирует свои веса и параметры, чтобы уменьшить ошибку предсказания. Валидационная выборка используется для оценки модели и последующей корректировки весов во время обучения, а тестовая — для итоговой оценки качества модели.

В качестве критерия для оценки точности каждой обученной модели нейронной сети применена метрика F1, рассчитанная по формуле [17]:

$$F1 = \frac{2 \times TP}{2 \times TP + FN + FP},$$

где TP (True Positive) — количество контуров лесных рубок (модель верно классифицировала как лесные рубки); FP (False Positive) — количество контуров объектов, не являющихся лесными рубками (модель ошибочно классифицировала как лесные рубки); FN (False Negative) — количество контуров лесных рубок (модель не классифицировала как лесные рубки).

Использование метрики F1 обусловлено тем, что она является достаточно информативной для сравнения качества работы различных нейросетевых моделей, и позволяет сбалансированно учитывать точность и пол-



*Рис. 1.* Образец 20-канального кадра из набора обучающих данных и маски контуров лесных рубок (1–10 — спектральные каналы космического снимка, выполненного до рубки, 11–20 — спектральные каналы космического снимка, выполненного после появления рубки, 21 — маска контуров лесных рубок)

*Fig. 1.* Sample of 20-channel frame from training dataset and felling mask (1–10 — spectral channels of the satellite image made before felling, 11–20 — spectral channels of the satellite image made after felling, 21 — felling mask)

ноту сегментации изображений. Данная метрика также используется в работах [2, 4, 6, 7, 10, 12] для оценки качества нейросетевых моделей.

В ходе обучения нейросетевых моделей критерием остановки тренировки служила динамика значений функции потерь (validation loss) на валидационной выборке. Данная функция отражает ошибку модели относительно истинных значений целевой переменной. Обучение продолжалось до тех пор, пока наблюдалось последовательное снижение функции потерь. Момент остановки тренировки определялся по началу колеба-

ний или росту значений функции потерь на валидационной выборке. Для удобства сравнения моделей на рис. 2 представлены графики метрики F1 до 15-й эпохи обучения, хотя оптимальные значения данной метрики для некоторых архитектур достигались начиная с 3-й эпохи. Для дальнейшей оценки производительности моделей выбирались состояния, соответствующие прекращению снижения функции потерь на валидационной выборке при достижении максимального значения метрики F1. Как видно из рис. 2, для пяти моделей значение метрики F1 изменяется в достаточно узком

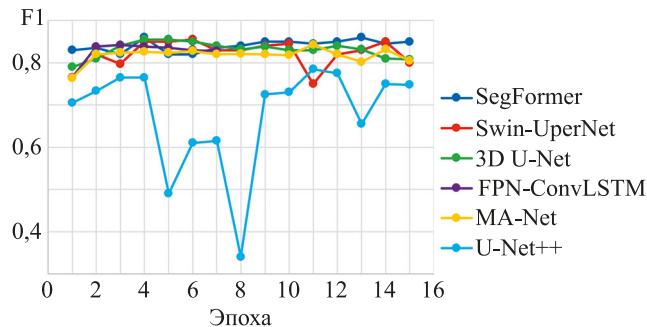


Рис. 2. Зависимости значений метрики F1 для исследуемых нейросетевых моделей от количества эпох обучения

Fig. 2. Dependence of F1 metric values for the studied neural network models vs. the number of training epochs

интервале от 0,75 до 0,9, а для модели U-Net++ — в широком диапазоне значений от 0,3 до 0,8.

После обучения исследуемых моделей проведено их сравнение на тестовой выборке с использованием метрики F1. Получены следующие результаты анализа исследуемых моделей для: SegFormer значение метрики 0,767; Swin-UpperNet — 0,712; 3D U-Net — 0,676; FPN-ConvLSTM — 0,675; MA-Net — 0,475; U-Net++ — 0,409. Видно, что трансформерная нейронная сеть SegFormer показала наилучшие результаты. В то же время нейросетевая модель U-Net++, успешно используемая для сегментации лесных рубок по зимним космическим снимкам [7], продемонстрировала наихудший результат для летних снимков. Рассчитанные по тестовой выборке значения метрики F1 указывают на то, что обученная нейронная сеть SegFormer, демонстрирующая приемлемую величину точности обнаружения лесных рубок, может быть использована в практических задачах для оперативного выявления новых лесных рубок по паре летних разновременных космических снимков.

Обучение каждой из рассмотренных моделей проводилось на персональном компьютере с 8-ядерным центральным процессором IntelCore i7-9800X с тактовой частотой 3,8 ГГц, оперативной памятью 48 ГБ и двумя видеокартами NVIDIA GeForce RTX 2080Ti с 11 ГБ видеопамяти в течении 48 ч.

Рассмотрим более подробно архитектуру модели нейронной сети SegFormer [14], с лучшим результатом по выявлению лесных рубок по летним космическим снимкам. SegFormer содержит два основных модуля: кодировщика и декодировщика (рис. 3). Модуль кодировщика состоит из последовательности четырех блоков трансформеров, которые выявляют признаки, относящиеся к искуемому объекту, в рассматриваемом случае — к лесной рубке. Первый блок трансформера позволяет выявить признаки высокого разрешения, а последний — признаки низкого разрешения, что повышает эффективность семантической сегментации изображения.

Модуль декодировщика последовательно выполняет три основных этапа. На этапе 1 разноуровневые признаки, полученные от кодировщика, проходят через унифицирующий многослойный персептрон, который предназначен для преобразования размерности разноуровневых признаков из кодировщика. Напомним, что многослойный персептрон — тип искусственной нейронной сети, состоящей из входного слоя, одного или нескольких скрытых слоев и выходного слоя, где каждый нейрон одного слоя связан со всеми нейронами следующего слоя. На этапе 2 признаки увеличиваются в размерности и объединяются в куб. На этапе 3 результатирующий многослойный персептрон объединяет признаки, находящиеся в кубе данных, полученные на этапе 2, и на основе объединенных признаков формируется слой с маской искуемого объекта, т. е. применительно к поставленной задаче — маской новых выявленных рубок.

В рамках данного исследования проведен эксперимент по сравнению результатов работы обученной нейросетевой модели SegFormer и традиционного метода визуального дешифрирования для выявления новых лесных рубок по паре полноразмерных разновременных космических снимков. Для эксперимента были выбраны две пары снимков на территории площадью 10 000 км<sup>2</sup> каждая, не использовавшиеся при обучении модели. В ходе эксперимента два специалиста независимо друг от друга выявляли новые лесные рубки на каждой паре снимков, первый — с помощью обученной

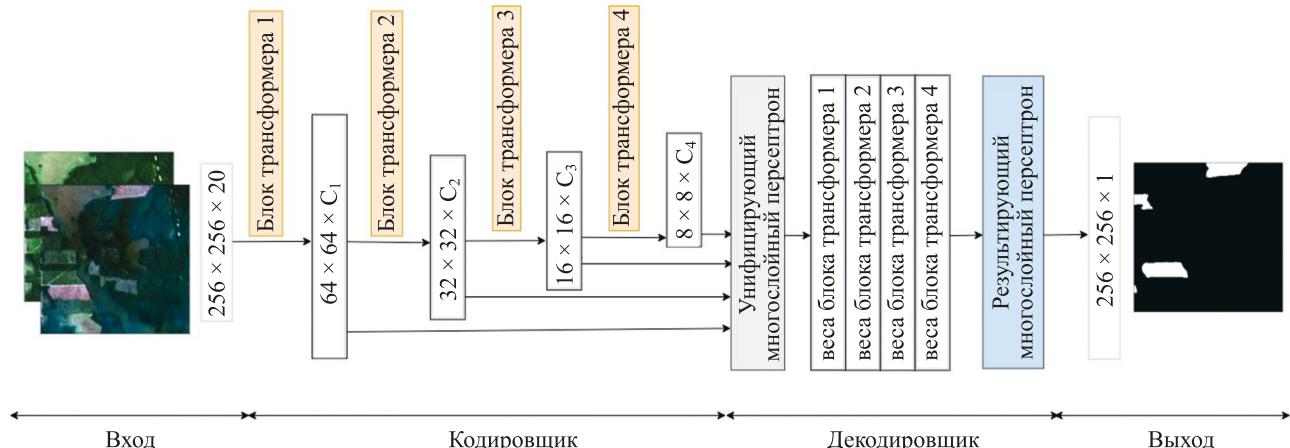


Рис. 3. Архитектура трансформерной нейронной сети SegFormer

Fig. 3. Architecture of the SegFormer transformer neural network

модели SegFormer, второй — традиционным способом визуального дешифрирования.

На следующем этапе эксперимента независимый эксперт провел сравнение результатов работы нейросетевой модели и метода визуального дешифрирования. Суммарно в ходе эксперимента получено 219 уникальных полигонов, из них 70 полигонов найдены как с использованием модели, так и традиционным визуальным способом, и действительно являлись новыми лесными рубками. Модель смогла обнаружить 6 рубок, пропущенных визуальным способом, в то же время специалист визуальным способом выявил 29 рубок, не найденных моделью. Модель также ошибочно приняла за рубки 114 полигонов, выделяя облака и тени от них или другие лесные участки, не содержащие рубок.

Хотя по результатам проведенного эксперимента модель и показала меньшую точность, чем при обучении, в основном за счет большого количества ложных срабатываний, время обработки одной пары снимков с использованием модели составило около 15 мин, в то время как специалисту для визуального дешифрирования потребовалось более 4 ч. Проведенный эксперимент продемонстрировал перспективность использования трансформерных нейросетевых моделей для автоматизации процессов дешифрирования космических снимков прежде всего за счет скорости обработки данных, что является несомненным преимуществом при анализе данных дистанционного зондирования Земли на такие обширные территории как, например, ХМАО.

## Заключение

В работе представлены результаты сравнительного анализа точности и эффективности сверточных и трансформерных нейросетевых моделей для картографирования лесных рубок по летним космическим снимкам Sentinel-2 на примере территории Ханты-Мансийского автономного округа. Результаты исследования показали, что трансформерная нейронная сеть SegFormer продемонстрировала наилучшие показатели точности выявления лесных рубок по сравнению с другими рассмотренными моделями.

Эксперимент по сравнению эффективности модели SegFormer и традиционного метода визуального дешифрирования космических снимков подтвердил перспективность использования нейросетевых методов для автоматизации процессов картографирования различных объектов, например, лесных рубок. Несмотря на то, что на текущем этапе модель SegFormer уступает традиционным методам дешифрирования по точности, она значительно превосходит их по скорости анализа космических снимков, что является важным показателем для экологического контроля обширных территорий лесных регионов, таких как Ханты-Мансийский автономный округ.

Для дальнейшего повышения точности нейросетевой модели необходимо проведение дополнительных исследований, направленных на расширение объема и улучшение качества обучающей выборки, включение в нее более разнообразных примеров лесных рубок. Также возможно исследовать влияние кадров, содержащих облака, тени от облаков и другие объекты, которые могут быть ошибочно классифицированы моделью как рубки, на качество работы нейросетевой модели.

## Литература

- Габдрахманов Р.М., Кочергин Г.А., Куприянов М.А., Хамедов В.А., Шарафутдинов Р.Р. Реестр изменений лесного фонда ХМАО — Югры. Свидетельство о регистрации базы данных RU2016620648. 2016.
- Torres D.L., Turnes J.N., Soto Vega P.J., Feitosa R.Q., Silva D.E., Marcato Junior J., Almeida C. Deforestation detection with fully convolutional networks in the Amazon Forest from Landsat-8 and Sentinel-2 images // Remote Sensing. 2021. V. 13. N 24. P. 5084. <https://doi.org/10.3390/rs13245084>
- Khan S.H., He X., Porikli F., Bennamoun M. Forest change detection in incomplete satellite images with deep neural networks // IEEE Transactions on Geoscience and Remote Sensing. 2017. V. 55. N 9. P. 5407–5423. <https://doi.org/10.1109/tgrs.2017.2707528>
- John D., Zhang C. An attention-based U-Net for detecting deforestation within satellite sensor imagery // International Journal of Applied Earth Observation and Geoinformation. 2022. V. 107. P. 102685. <https://doi.org/10.1016/j.jag.2022.102685>
- Podoprigorova N.S., Savchenko G.A., Rabcevich K.R., Kanev A.I., Tarasov A.V., Shikohov A.N. Forest damage segmentation using machine learning methods on satellite images // Studies in Computational Intelligence. 2023. V. 1120. P. 380–388. [https://doi.org/10.1007/978-3-031-44865-2\\_41](https://doi.org/10.1007/978-3-031-44865-2_41)
- Бычков И.В., Ружников Г.М., Федоров Р.К., Попова А.К., Авраменко Ю.В. Классификация космоснимков Sentinel-2 Байкальской природной территории // Компьютерная оптика. 2022. Т. 46. № 1. С. 90–96. <https://doi.org/10.18287/2412-6179-co-1022>
- Мельников А.В., Кочергин Г.А., Аббазов В.Р., Байсалымова О.А., Рusanov M.A., Polishchuk Yu.M. Нейросетевая модель для сегмен-

## References

- Gabdrakhmanov R.M., Kochergin G.A., Kupriyanov M.A., Khamedov V.A., Sharafutdinov R.R. Register of changes in the forest fund of Khanty-Mansiysk Autonomous Okrug — Yugra. *Certificate of registration of the database RU2016620648*, 2016.
- Torres D.L., Turnes J.N., Soto Vega P.J., Feitosa R.Q., Silva D.E., Marcato Junior J., Almeida C. Deforestation detection with fully convolutional networks in the Amazon Forest from Landsat-8 and Sentinel-2 images. *Remote Sensing*, 2021, vol. 13, no. 24, pp. 5084. <https://doi.org/10.3390/rs13245084>
- Khan S.H., He X., Porikli F., Bennamoun M. Forest change detection in incomplete satellite images with deep neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, vol. 55, no. 9, pp. 5407–5423. <https://doi.org/10.1109/tgrs.2017.2707528>
- John D., Zhang C. An attention-based U-Net for detecting deforestation within satellite sensor imagery. *International Journal of Applied Earth Observation and Geoinformation*, 2022, vol. 107, pp. 102685. <https://doi.org/10.1016/j.jag.2022.102685>
- Podoprigorova N.S., Savchenko G.A., Rabcevich K.R., Kanev A.I., Tarasov A.V., Shikohov A.N. Forest damage segmentation using machine learning methods on satellite images. *Studies in Computational Intelligence*, 2023, vol. 1120, pp. 380–388. [https://doi.org/10.1007/978-3-031-44865-2\\_41](https://doi.org/10.1007/978-3-031-44865-2_41)
- Bychkov I.V., Ruzhnikov G.M., Fedorov R.K., Popova A.K., Avramenko Y.V. Classification of Sentinel-2 satellite images of the Baikal Natural Territory. *Computer Optics*, 2022, vol. 46, no. 1, pp. 90–96. (in Russian). <https://doi.org/10.18287/2412-6179-co-1022>
- Melnikov A.V., Kochergin G.A., Abbazov V.R., Baisalamova O.A., Rusanov M.A., Polishchuk Yu.M. A neural network model for space image segmentation in monitoring of deforestation factors. *Bulletin*

- тации космических снимков в мониторинге факторов обезлесения территории // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. 2023. Т. 23. № 3. С. 5–15. <https://doi.org/10.14529/ctcr230301>
8. Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for Sentinel-2 // Proceedings of SPIE. 2017. V. 10427. P. 1042704. <https://doi.org/10.1117/12.2278218>
9. Garnot V.S.F., Landrieu L. Panoptic segmentation of satellite image time series with convolutional temporal attention networks // Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021. P. 4852–4861. <https://doi.org/10.1109/iccv48922.2021.00483>
10. Rustowicz R., Cheong R., Wang L., Ermon S., Burke M., Lobell D. Semantic segmentation of crop type in Africa: A novel dataset and analysis of deep learning methods // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops. 2019. P. 75–82.
11. Fan T., Wang G., Li Y., Wang H. MA-Net: A multi-scale attention network for liver and tumor segmentation // IEEE Access. 2020. V. 8. P. 179656–179665. <https://doi.org/10.1109/access.2020.3025372>
12. Chamorro Martinez J.A., Cué La Rosa L.E., Feitosa R.Q., Sanches I.D., Happ P.N. Fully convolutional recurrent networks for multiday crop recognition from multitemporal image sequences // ISPRS Journal of Photogrammetry and Remote Sensing. 2021. V. 171. P. 188–201. <https://doi.org/10.1016/j.isprsjprs.2020.11.007>
13. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W., Woo W. Convolutional LSTM network: A machine learning approach for precipitation nowcasting // arXiv. 2015. arXiv:1506.04214. <https://doi.org/10.48550/arXiv.1506.04214>
14. Xie E., Wang W., Yu Z., Anandkumar A., Alvarez J.M., Luo P. SegFormer: Simple and efficient design for semantic segmentation with transformers nowcasting // arXiv. 2021. arXiv:2105.15203. <https://doi.org/10.48550/arXiv.2105.15203>
15. Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z., Lin S., Guo B. Swin transformer: Hierarchical vision transformer using shifted Windows // Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021. P. 9992–10002. <https://doi.org/10.1109/iccv48922.2021.00986>
16. Kruitwagen L. Towards DeepSentinel: An extensible corpus of labelled Sentinel-1 and -2 imagery and a general-purpose sensor-fusion semantic embedding model // arXiv. 2021. arXiv:2102.06260. <https://doi.org/10.48550/arXiv.2102.06260>
17. Betzalel E., Penso C., Navon A., Fetaya E. A study on the evaluation of generative models // arXiv. 2022. arXiv:2206.10935. <https://doi.org/10.48550/arXiv.2206.10935>
- of the South Ural State University. Series Computer Technology, Automatic Control, Radio Electronics, 2023, vol. 23, no. 3, pp. 5–15. (in Russian). <https://doi.org/10.14529/ctcr230301>
8. Main-Knorn M., Pflug B., Louis J., Debaecker V., Müller-Wilm U., Gascon F. Sen2Cor for Sentinel-2. *Proceedings of SPIE*, 2017, vol. 10427, pp. 1042704. <https://doi.org/10.1117/12.2278218>
9. Garnot V.S.F., Landrieu L. Panoptic segmentation of satellite image time series with convolutional temporal attention networks. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021, pp. 4852–4861. <https://doi.org/10.1109/iccv48922.2021.00483>
10. Rustowicz R., Cheong R., Wang L., Ermon S., Burke M., Lobell D. Semantic segmentation of crop type in Africa: A novel dataset and analysis of deep learning methods. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshop*, 2019, pp. 75–82.
11. Fan T., Wang G., Li Y., Wang H. MA-Net: A multi-scale attention network for liver and tumor segmentation. *IEEE Access*, 2020, vol. 8, pp. 179656–179665. <https://doi.org/10.1109/access.2020.3025372>
12. Chamorro Martinez J.A., Cué La Rosa L.E., Feitosa R.Q., Sanches I.D., Happ P.N. Fully convolutional recurrent networks for multiday crop recognition from multitemporal image sequences. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, vol. 171, pp. 188–201. <https://doi.org/10.1016/j.isprsjprs.2020.11.007>
13. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W., Woo W. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *arXiv*, 2015, arXiv:1506.04214. <https://doi.org/10.48550/arXiv.1506.04214>
14. Xie E., Wang W., Yu Z., Anandkumar A., Alvarez J.M., Luo P. SegFormer: Simple and efficient design for semantic segmentation with transformers nowcasting. *arXiv*, 2021, arXiv:2105.15203. <https://doi.org/10.48550/arXiv.2105.15203>
15. Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z., Lin S., Guo B. Swin transformer: Hierarchical vision transformer using shifted Windows. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021, pp. 9992–10002. <https://doi.org/10.1109/iccv48922.2021.00986>
16. Kruitwagen L. Towards DeepSentinel: An extensible corpus of labelled Sentinel-1 and -2 imagery and a general-purpose sensor-fusion semantic embedding model. *arXiv*, 2021, arXiv:2102.06260. <https://doi.org/10.48550/arXiv.2102.06260>
17. Betzalel E., Penso C., Navon A., Fetaya E. A study on the evaluation of generative models. *arXiv*, 2022, arXiv:2206.10935. <https://doi.org/10.48550/arXiv.2206.10935>

## Авторы

**Мельников Андрей Витальевич** — доктор технических наук, профессор, директор, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск 628011, Российская Федерация; профессор, Югорский государственный университет, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0000-0002-1073-7108>, melnikovav@uriit.ru

**Полищук Юрий Михайлович** — доктор физико-математических наук, профессор, главный научный сотрудник, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0000-0002-4944-4919>, polichukjm@uriit.ru

**Рusanov Михаил Александрович** — руководитель центра, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск 628011, Российская Федерация; старший преподаватель, Югорский государственный университет, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0000-0002-9926-4609>, rusanovma@uriit.ru

**Аббазов Валерьян Ринатович** — ведущий программист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0009-0008-9315-2041>, abbazovvr@uriit.ru

**Кочергин Глеб Александрович** — кандидат технических наук, руководитель центра, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российской Федерации; доцент, Югорский государственный университет, Ханты-Мансийск, 628011, Российской Федерации, <https://orcid.org/0009-0001-4875-7489>, kocherginga@uriit.ru

## Authors

**Andrey V. Melnikov** — D.Sc., Professor, Director, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation; Professor, Yugra State University, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0000-0002-1073-7108>, melnikovav@uriit.ru

**Yuri M. Polishchuk** — D.Sc. (Physics & Mathematics), Professor, Chief Researcher, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0000-0002-4944-4919>, polichukjm@uriit.ru

**Mikhail A. Rusanov** — Head of the Center, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation 628011, Российской Федерации; Senior Lecturer, Yugra State University, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0000-0002-9926-4609>, rusanovma@uriit.ru

**Valerian R. Abbazov** — Leading Software Developer, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, 628011, Российской Федерации, <https://orcid.org/0009-0008-9315-2041>, abbazovvr@uriit.ru

**Gleb A. Kochergin** — PhD, Head of the Center, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation; Associate Professor, Yugra State University, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0009-0001-4875-7489>, kocherginga@uriit.ru

**Куприянов Матвей Андреевич** — главный специалист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0000-0002-9476-2887>, kupriyanovma@uriit.ru

**Байсалимова Оксана Ахметсафаевна** — главный специалист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0009-0000-0633-3832>, baysalyamovaoa@uriit.ru

**Соколов Олег Игоревич** — программист, Югорский научно-исследовательский институт информационных технологий, Ханты-Мансийск, 628011, Российская Федерация, <https://orcid.org/0009-0006-5869-1395>, sokolkovo@uriit.ru

**Matvey A. Kupriyanov** — Chief Specialist, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0000-0002-9476-2887>, kupriyanovma@uriit.ru

**Oksana A. Baisalyamova** — Chief Specialist, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, <https://orcid.org/0009-0000-0633-3832>, baysalyamovaoa@uriit.ru

**Oleg I. Sokolkov** — Software Developer, Ugra Research Institute of Information Technologies, Khanty-Mansiysk, 628011, Russian Federation, 628011, Российской Федерации, <https://orcid.org/0009-0006-5869-1395>, sokolkovo@uriit.ru

Статья поступила в редакцию 28.06.2024

Одобрена после рецензирования 17.08.2024

Принята к печати 26.09.2024

Received 28.06.2024

Approved after reviewing 17.08.2024

Accepted 26.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

УДК 004.052

doi: 10.17586/2226-1494-2024-24-5-815-823

## Гарантированные оценки гамма-процентного остаточного ресурса оборудования систем хранения данных

Михаил Иванович Ломакин<sup>1</sup>✉, Александр Владимирович Докукин<sup>2</sup>,  
Ирина Юрьевна Олтян<sup>3</sup>, Юлия Михайловна Ниязова<sup>4</sup>

<sup>1,2,3</sup> Всероссийский научно-исследовательский институт по проблемам гражданской обороны и чрезвычайных ситуаций МЧС России, Москва, 121352, Российская Федерация

<sup>4</sup> Московский государственный университет геодезии и картографии, Москва, 105064, Российская Федерация

<sup>1</sup> lomakin@vniigochs.ru✉, <https://orcid.org/0000-0003-4191-1348>

<sup>2</sup> dokukin@vniigochs.ru, <https://orcid.org/0000-0002-3342-8770>

<sup>3</sup> oltyan@vniigochs.ru, <https://orcid.org/0000-0002-2178-5033>

<sup>4</sup> y\_niyazova@edu.miigaik.ru, <https://orcid.org/0000-0001-5589-4855>

### Аннотация

**Введение.** Активное развитие цифровых технологий, технологии интернета вещей, виртуальных испытаний требуют увеличения объемов собираемой и используемой информации, которая размещается в системах хранения данных (СХД). Стремительный рост объема данных ведет к ужесточению требований к СХД, например, основного их них — повышение надежности хранения больших объемов информации. Данное требование предполагает необходимость оценки надежности оборудования СХД. Для этих целей требуется оценка таких показателей надежности как вероятность безотказной работы, вероятность отказов, средний остаточный ресурс, гамма-процентный ресурс. Традиционно показатели надежности оцениваются при экспоненциальном распределении времени отказа. В реальной ситуации выборки времени отказов оборудования СХД являются малыми, по которым невозможно однозначно идентифицировать исходное распределение. В работе предложена модель оценки показателей надежности как гамма-процентный остаточный ресурс в условиях неполных данных, представленных малыми выборками случайных величин времени безотказной работы оборудования. Научная новизна работы состоит в получении общего решения задачи определения гарантированного гамма-процентного остаточного ресурса оборудования в условиях неполных данных, представленной малыми выборками наработок до отказа оборудования. **Метод.** Математическая формализация задачи оценки гамма-процентного остаточного ресурса оборудования СХД в условиях неполных данных, представленных малыми выборками, выполнена в виде модели стохастического уравнения. Решением уравнения является гарантированная (нижняя, верхняя) оценка гамма-процентного остаточного ресурса оборудования. **Основные результаты.** Предложена модель оценки гамма-процентного остаточного ресурса оборудования СХД в условиях неполных данных. Решена в общем случае задача нахождения гарантированных (нижних и верхних) оценок гамма-процентного остаточного ресурса оборудования на множестве функций распределения времени безотказной работы оборудования с заданными моментами, равными выборочным моментам, определяемым по малым выборкам. При двух моментах времени безотказной работы оборудования получены аналитические соотношения для определения гамма-процентного остаточного ресурса. Работоспособность модели продемонстрирована на примере определения нижней гарантированной оценки гамма-процентного остаточного ресурса модели дискового массива HP EVA P6500. **Обсуждение.** Полученные результаты могут быть использованы специалистами при оценке и оптимизации гамма-процентного остаточного ресурса оборудования СХД.

### Ключевые слова

система хранения данных, гамма-процентный ресурс, модель, моменты распределения, вероятность, гарантированные оценки

**Ссылка для цитирования:** Ломакин М.И., Докукин А.В., Олтян И.Ю., Ниязова Ю.М. Гарантированные оценки гамма-процентного остаточного ресурса оборудования систем хранения данных // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 815–823. doi: 10.17586/2226-1494-2024-24-5-815-823

## Guaranteed estimates of the gamma percent residual life of data storage equipment

Mikhail I. Lomakin<sup>1</sup>✉, Alexander V. Dokukin<sup>2</sup>, Irina Yu. Olyyan<sup>3</sup>, Yulia M. Niyazova<sup>4</sup>

<sup>1,2,3</sup> All-Russian Scientific Research Institute for Civil Defense and Emergencies of the EMERCOM of Russia, Moscow, 121352, Russian Federation

<sup>4</sup> Moscow State University of Geodesy and Cartography, Moscow, 105064, Russian Federation

<sup>1</sup> lomakin@vniigochs.ru✉, <https://orcid.org/0000-0003-4191-1348>

<sup>2</sup> dokukin@vniigochs.ru, <https://orcid.org/0000-0002-3342-8770>

<sup>3</sup> olyyan@vniigochs.ru, <https://orcid.org/0000-0002-2178-5033>

<sup>4</sup> y\_niyazova@edu.miigaik.ru, <https://orcid.org/0000-0001-5589-4855>

### Abstract

The active development of digital technologies, Internet of Things technologies, and virtual tests requires an increase in the volume of information collected and used, which is placed in data storage systems. The rapid growth of data volume leads to stricter requirements for storage. One of the main requirements for storage is to increase the reliability of storing large amounts of information. This implies the need to assess the reliability of storage equipment. For these purposes, it is necessary to evaluate such reliability indicators as the probability of failure-free operation, the probability of failures, the average residual resource, and the gamma percent resource. Traditionally, reliability indicators are evaluated with an exponential distribution of failure time. In a real situation, the samples of failure times of storage equipment are small, for which it is impossible to uniquely identify the initial distribution. In this article, a model is proposed for evaluating reliability indicators as a gamma percent residual resource in conditions of incomplete data presented by small samples of random variables of equipment uptime. The scientific novelty of the presented work consists in obtaining a general solution to the problem of determining the guaranteed gamma percent residual life of equipment in conditions of incomplete data presented by small samples of developments before equipment failure. The mathematical formalization of the problem of estimating the gamma percent residual life of storage equipment in conditions of incomplete data presented by small samples is performed in the form of a stochastic equation model, the solution of which is a guaranteed (lower, upper) estimate of the gamma percent residual life of equipment. A model for estimating the gamma percent residual life of storage equipment in conditions of incomplete data is presented. In the general case, the problem of finding guaranteed (lower and upper) estimates of the gamma percent residual life of equipment on a set of functions for the distribution of uptime of equipment with specified moments equal to sample moments determined from small samples is solved. At two points in the uptime of the equipment, analytical ratios were obtained to determine the gamma percent residual life. The performance of the model is demonstrated by the example of determining the lower guaranteed estimate of the gamma percent residual resource of the HP EVA P6500 disk array model. The results obtained can be used by specialists in evaluating and optimizing the gamma percent residual life of storage equipment.

### Keywords

data storage system, gamma percentage resource, model, distribution moments, probability, guaranteed estimates

**For citation:** Lomakin M.I., Dokukin A.V., Olyyan I.Yu., Niyazova Yu.M. Guaranteed estimates of the gamma percent residual life of data storage equipment. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 815–823 (in Russian). doi: 10.17586/2226-1494-2024-24-5-815-823

### Введение

В настоящее время наблюдается стремительный рост объема данных, используемых в информационных системах. Согласно докладу Международной корпорации данных в 2019 году этот объем составлял примерно 45 зеттабайт, а в 2025 — 175 зеттабайт<sup>1</sup> [1, 2]. Эффективное хранение таких больших объемов информации выдвигает жесткие требования к системам хранения данных (СХД).

СХД (или дисковая подсистема) — совокупность специализированного оборудования и программного обеспечения, которая предназначена для хранения и передачи больших массивов информации. СХД обеспечивает возможность организации хранения и ввода-вывода данных за счет использования дисковых площадок, характеризуемых [3] оптимальным распределением ресурсов.

Характерным представителем СХД данного класса являются дисковые массивы RAID<sup>2</sup> (избыточный массив независимых дисков), состоящие из  $n$  дисков, устойчивых к отказам до  $s - 1$  дисков и отказывающих вместе с потерей всех данных при отказе  $s$  и более дисков [4], и требующие пересоздания массива «с нуля» и восстановления данных из резервной копии.

Одним из основных требований к СХД, наряду с показателями, характеризующими скорость ввода-вывода данных и временем, необходимым для восстановления после сбоя, является надежность хранения. В связи с этим изучению вопросов экономически эффективного обеспечения требуемого уровня надежности функционирования оборудования СХД посвящен целый ряд работ [4–24]. В [5–13] изучены базовые методологические проблемы обеспечения надежности СХД, в том

<sup>1</sup> 1 зеттабайт равен  $10^9$  терабайт

<sup>2</sup> RAID (Redundant Array of Independent Disks) — это метод виртуализации («избыточный массив независимых дисков»). Представляет собой технологию, позволяющую объединять несколько дисков в единый логический том — с улучшенными параметрами.

числе методы построения высоконадежных, отказоустойчивых СХД.

В большом количестве исследований для оценки показателей надежности использован математический аппарат моделирования на основе применения цепей Маркова. Данный математический аппарат дает возможность оценки целого ряда показателей, характеризующих надежность СХД, включая среднее время наработки на отказ и восстановления, коэффициент готовности. Например, в работе [4] рассмотрен «набор состояний каждого фрагмента данных. Состояние 0 будет соответствовать неповрежденному кортежу из дисковых блоков. Отказ диска будет приводить к переходу из состояния  $i$  в состояние  $i + 1$ . Восстановление утраченного дискового блока будет соответствовать переходу из состояния  $i$  в состояние  $i - 1$ . Переход в состояние с индексом  $n - k + 1$  будет означать необратимую потерю данных. Такие состояния называются поглощающими, поскольку, однажды попав в него, система остается в нем навсегда. Поскольку вероятности перехода между состояниями в такой модели не зависят от предыстории, то такая система является классической цепью Маркова с непрерывным временем».

Полученная СХД описывается с помощью системы уравнений Колмогорова, в которой используются интенсивности перехода СХД из некоторого  $i$ -го состояния в  $j$ -е состояние. При этом предполагается, что данные интенсивности известны. В связи с тем, что количество дисков в СХД велико, то и количество состояний в системе уравнений Колмогорова также экспоненциально растет. При этом в [4] предложен «метод нахождения приближенно асимптотического решения для случая, когда среднее время между дискомыми отказами много больше времени восстановления после отказа». Этот метод также предполагает наличие полной информации об интенсивностях перехода системы.

В работах [14–16] использованы результаты работ [17, 18] и рассмотрены несколько специализированных моделей отказоустойчивой СХД. Исследователи исходят из предположения, что отказоустойчивый массив данных состоит из множества элементов с идентичными характеристиками, при этом он остается работоспособным при отказе не более  $s - 1$  элементов. Также полагаются известными интенсивности перехода отказоустойчивого массива данных из состояния  $j = 0 \dots s - 1$  в следующее состояние  $j + 1$ , вследствие сбоя функционирования очередного элемента. Кроме того, также полагаются известными интенсивности перехода из работоспособных состояний отказоустойчивого массива данных одномоментно в аварийное состояние  $s$  по причине критической ошибки системы управления массивом. Далее в работах [14–16] использована система уравнений Колмогорова, из которой с помощью предложенной рекуррентной схемы вычислений получены соответствующие показатели надежности СХД. Приведены примеры оценки показателей надежности для дисковых массивов с чередованием данных RAID-0, RAID-5 и RAID-6. Отметим, что в [14–16] предположено, что известна полная информация об интенсивностях переходов.

В [19] развиваются идеи работ [14–16, 20–22] и разработаны модели надежности на основе уравнений Колмогорова для массивов дисков RAID-5, RAID-6, RAID-10.

Входными параметрами моделей надежности является группа параметров, характеризующая интенсивность RAID: отказов дисков в RAID-массиве (одинакова для всех дисков), регенерации данных для диска в RAID-массиве, ошибок чтения диска в RAID-массиве, ошибок управляющего программного обеспечения, полного восстановления системы из аварийного состояния. Выходными параметрами моделей являются: среднее время наработки на отказ, коэффициент готовности, среднее время восстановления.

В работах [23, 24] оценивание характеристик надежности СХД выполнено с учетом типичного профиля функционирования СХД, включая такие показатели, как соотношение операций ввода и вывода данных, последовательного или случайного режима операций ввода/вывода данных, размеров информационного блока данных, объема проводимых операций ввода и вывода. Особенности указанных профилей учтены в модели за счет указания величин коэффициентов у соответствующих интенсивностей переходов СХД из одного состояния в другое или интенсивностей потока обслуженных заявок на ввод/вывод данных.

В [11, 25] рассмотрены вопросы анализа и оптимизации готовности компьютерной системы с учетом ее структуры, в которой узлы являются дублированными компьютерными системами. Произведен анализ готовности компьютерной системы к выполнению запросов с помощью марковских моделей с известными интенсивностями переходов.

В работе [26] анализируется информационная система с контейнерной виртуализацией, модель которой представлена многоканальной системой массового обслуживания с неограниченной очередью, входной поток рассматривается как простейший с экспоненциальной организацией обслуживания.

В [4, 11, 14–26] предположено, что известна полная информация об интенсивностях переходов СХД из некоторого  $i$ -го состояния в некоторое  $j$ -е состояние, что не совсем соответствует реальной ситуации. В работе [22] при анализе надежности оборудования СХД приведены статистические данные об отказах и сбоях оборудования (дисковых массивов): HP XP24000, HP EVA P6500, HP EVA P6350, IBM STORWIZE V7000 за 2014–2018 гг., количество отказов которых составляет несколько единиц на несколько сотен дисков. Например, в модели дискового массива HP XP24000, состоящего из 312 дисков в 2018 г. было всего четыре отказа дисков. Это говорит о том, что информация об отказах оборудования СХД представлена малыми выборками, по которым нельзя оценить достоверно интенсивности переходов для уравнений Колмогорова.

Кроме того, следует отметить, что показатели долговечности СХД в известных работах практически не рассматривались. В [19] предложено соотношение для среднего ресурса СХД при условии, что распределение наработки оборудования СХД до отказа (или ее элементов) является экспоненциальным, с известными

параметрами и известен коэффициент запаса устойчивости по ресурсу записи (считывания). При этом об остаточном среднем ресурсе только упоминается, хотя этот ресурс является достаточно важным, в частности, для принятия решений о замене элементов СХД.

Цель настоящей работы состоит в определении такого показателя долговечности СХД как гамма-процентный остаточный ресурс в условиях неполных данных, представленных малой выборкой времени безотказной работы оборудования СХД.

### Постановка задачи

При исследовании процессов функционирования СХД возникает необходимость в оценке их долговечности. Оценку долговечности информационных систем, в том числе и оборудования СХД и их элементов, проводят с помощью показателей остаточного ресурса. Как правило, используют такие показатели как средний остаточный ресурс и гамма-процентный остаточный ресурс [27]. Для систем, по которым имеется достаточная статистическая информация о процессах их функционирования, представленная наработками до отказа, по которым можно однозначно идентифицировать исходное распределение времени наработки до отказа, задача оценки показателей остаточного ресурса достаточно исследована в ряде работ [27–31].

Гарантированные оценки среднего остаточного ресурса (а также гарантированные оценки высших моментов остаточного ресурса) технической системы при неполной информации об исходных распределениях времени наработки на отказ представлены в работе [31], гарантированные оценки остаточного среднего времени развития чрезвычайной ситуации как остаточного ресурса некоторой системы получены в работе [32].

Пусть  $x$  — время безотказного функционирования оборудования СХД, например, дискового массива. Под остаточным временем функционирования сверх времени  $y$  будем понимать длительность функционирования СХД от момента  $y$  до возникновения отказа (до предельного состояния) [27].

Обозначим значение остаточного времени функционирования оборудования СХД через условную случайную величину  $x_T$ . Тогда получим

$$x_T = (x - y)|_{(x > y)},$$

где « $|$ » — знак условия (это не знак деления).

Определим функцию распределения остаточного времени функционирования оборудования (остаточного ресурса) через случайную величину  $x_T$  в виде [28–31]:

$$\begin{aligned} G(t) &= P(x - y < t|x > y) = \frac{P(t < x < t + y)}{1 - F(t)} = \\ &= \frac{F(t + y) - F(t)}{1 - F(y)} = 1 - \frac{P(t + y)}{P(y)}, \end{aligned}$$

где  $P(t) = 1 - F(t)$  — вероятность безотказной работы оборудования;  $F(t)$  — функция распределения времени функционирования оборудования.

Получим гамма-процентный остаточный ресурс из уравнения [27–30]

$$\frac{P(t + y)}{P(y)} = \frac{\gamma}{100} = \beta. \quad (1)$$

Из уравнения (1) найдем  $t = T_\gamma(y)$ , параметр  $\gamma$  — измеряется в процентах.

Пусть  $xv = (xv_1, xv_2, \dots, xv)$  — выборка значений случайной величины  $x$ . Составляющие выборки  $xv_i > 0$  — независимые одинаково распределенные величины из некоторого неизвестного распределения  $F(t)$ . Выборка  $xv$  является конечной выборкой малого объема, по которой невозможно восстановить исходное распределение  $F(t)$ .

Необходимо на основе выборки  $xv$  определить оценки гамма-процентного остаточного ресурса оборудования СХД  $t = T_\gamma(\tau)$ .

### Метод решения поставленной задачи

Найдем на основе выборки  $x$  начальные моменты (далее — моменты) случайной величины  $x$ :

$$m_j = \frac{1}{n} \sum_{i=1}^n xv_i^j; j = \overline{1, k}; k > 0. \quad (2)$$

Определим аналогично [30–35] множество функций распределения  $F_0$ , имеющих (известных)  $k$  моментов, равных моментам, определенным в соответствии с выражением (2), в виде:

$$F_0 = \{F(t): \int_0^\infty t^j dF(t) = m_j, j = \overline{1, k}\}. \quad (3)$$

Рассмотрим следующую задачу: найти гарантированные (нижние, верхние) оценки вероятности безотказной работы оборудования на множестве функций распределения, известных до моментов, определяемых выражением (3), т. е.

$$P_\Gamma(s) = \min_{F(t) \in F_0} (\max_{s \leq t} P(s)). \quad (4)$$

В выражении (4)  $P(s) = 1 - F(s)$ , где  $F(s)$  — функция распределения времени функционирования оборудования;  $s$  — переменная — время функционирования оборудования.

В работах [33, 34] получено общее решение задачи нахождения гарантированных (нижних и верхних) оценок функции распределения, на множестве функций распределения, известных до моментов.

Это решение состоит в следующем.

Наибольшее (наименьшее) значение интеграла

$$J(F) = \int_0^s c(t) dF(t)$$

при  $F(t) \in F_0$  достигается:

- на единственном ступенчатом распределении  $F(t)$ , у которого среди точек роста  $t_1, t_2, \dots, t_v$  имеется точка  $s$ ;
- при нечетном  $k$  число точек роста  $v$  функции распределения  $F(t)$  определяется соотношением  $v = (k + 3)/2$ , причем  $0 = t_1 < t_2 < \dots < t_v < \infty$ ;

- при четном  $k$  число точек роста  $v$  функции распределения  $F(t)$  определяется соотношением  $v = k/2 + 1$ , причем  $0 < t_1 < t_2 < \dots < t_v < \infty$ ;
- числа  $p_j > 0$ ,  $t_j, j = 1, 2, \dots, v$  удовлетворяют системе уравнений:

$$m_j = \sum_{i=1}^v t_i^j p_i; j = \overline{1, k}; k > 0.$$

Функция  $c(t)$  должна иметь неотрицательную  $k+1$ -ю производную.

В рассматриваемом случае  $c(t) = 1$ , следовательно, условие неотрицательности  $k+1$ -ой производной функции  $c(t) = 1$  выполняется.

Рассмотрим уравнения:

$$\begin{aligned} y_1 &= \frac{P(t+y)}{P(y)}; \\ y_2 &= \frac{\min_{F(t) \in F_0} P(t+y)}{P(y)}; \\ y_3 &= \frac{\max_{F(t) \in F_0} P(t+y)}{\min_{F(t) \in F_0} P(y)}; \\ y_4 &= \min_{F(t) \in F_0} P(t+y), \end{aligned}$$

примерные графики которых приведены на рис. 1.

Для любого  $y \geq 0$  имеет место неравенство:

$$\frac{P(t+y)}{P(y)} \geq \frac{\min_{F(t) \in F_0} P(t+y)}{P(y)} \geq \frac{\min_{F(t) \in F_0} P(t+y)}{\max_{F(t) \in F_0} P(y)} \geq \min_{F(t) \in F_0} P(t+y). \quad (5)$$

Из соотношения (5) следует, что в качестве нижней гарантированной оценки гамма-процентного остаточного ресурса могут быть использованы оценки  $T_3(y)$  или  $T_4(y)$ . Оценки  $T_1(y)$  и  $T_2(y)$  на основе имеющихся данных выборки  $x$  определены быть не могут.

Рассмотрим задачу нахождения верхней гарантированной оценки гамма-процентного остаточного ресурса оборудования, представленную следующими уравнениями:

$$\begin{aligned} y_5 &= \frac{\max_{F(t) \in F_0} P(t+y)}{P(y)}; \\ y_6 &= \frac{\max_{F(t) \in F_0} P(t+y)}{\min_{F(t) \in F_0} P(y)}; \\ y_7 &= \frac{1}{\min_{F(t) \in F_0} P(y)}, \end{aligned}$$

примерные графики которых показаны на рис. 2.

Для любого  $y \geq 0$  имеет место неравенство:

$$\frac{P(t+y)}{P(y)} \leq \frac{\max_{F(t) \in F_0} P(t+y)}{P(y)} \leq \frac{\max_{F(t) \in F_0} P(t+y)}{\min_{F(t) \in F_0} P(y)} \leq \frac{1}{\min_{F(t) \in F_0} P(y)}. \quad (6)$$

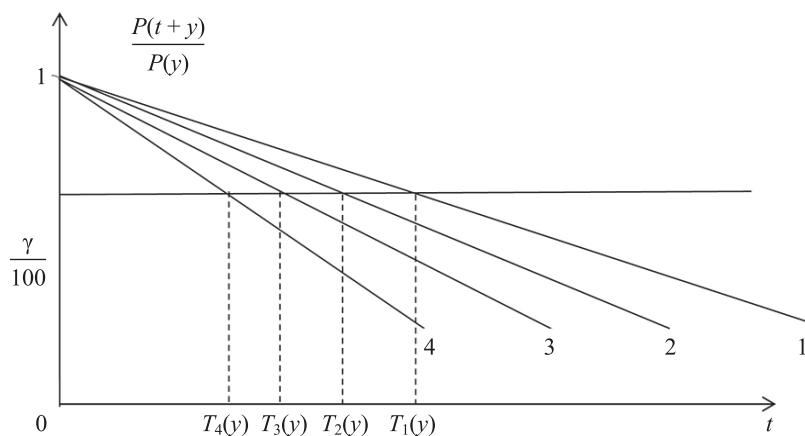
Из соотношения (6) следует, что в качестве верхней гарантированной оценки гамма-процентного остаточного ресурса могут быть использованы только  $T_6(y)$ . Оценки  $T_1(y)$ ,  $T_5(y)$  на основе имеющихся данных выборки  $x$  определены быть не могут. Оценка  $T_7(y)$  не существует, так как

$$\frac{1}{\min_{F(t) \in F_0} P(y)} \geq 1 \quad (7)$$

и левая часть неравенства (7) не зависит от  $t$ .

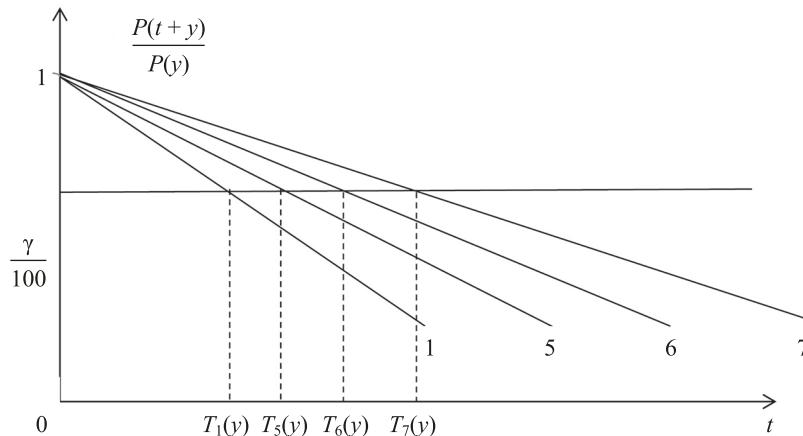
### Примеры нахождения гарантированных оценок гамма-процентного ресурса

**Исходные данные.** Рассмотрим пример определения нижней гарантированной оценки гамма-процентного остаточного ресурса модели дискового массива HP EVA P6500. Виртуальные дисковые массивы хранения HP EVA P6550 Storage линейки СХД EVA P6500 — масштабируемые СХД с двумя Fibre Channel/10GbE контроллерами [34]. Пусть известны два первых момента времени наработки на отказ одного диска из



Ruc. 1. Примерные графики уравнений  $y_1 - y_4$

Fig. 1. Example graphs of  $y_1 - y_4$

Рис. 2. Примерные графики уравнений  $y_1, y_5 - y_7$ Fig. 2. Example graphs of  $y_1, y_5 - y_7$ 

дискового массива  $\mu_1, \mu_2$ . По данным об отказах дискового массива, приведенным в работе [22], определены следующие значения первого и второго моментов:  $m_1 = 3,15 \cdot 10^5$  ч;  $m_2 = 1,47 \cdot 10^{11}$  ч<sup>2</sup>. Пусть также известны значения величины  $\gamma$ , которые заданы в интервале 0 до 100 % и значение  $y$ , которое лежит в пределах от 0 до  $m_1 = 3,15 \cdot 10^5$  ч.

**Аналитические соотношения для гарантированных оценок.** Необходимо определить гарантированные (нижние и верхние) оценки гамма-процентного остаточного ресурса диска из дискового массива HP EVA P6500.

В соответствии с работами [33, 34] имеем

$$\min_{F(t) \in F_0} P(t+y) = \frac{(m_1 - t - y)^2}{(m_1 - t - y)^2 + m_2 - m_1^2} \quad \text{при } 0 < t + y \leq m_1. \quad (8)$$

$$\max_{F(t) \in F_0} P(y) = 1 \quad \text{при } 0 < y \leq m_1. \quad (9)$$

Вследствие того, что имеет место соотношение (9), оценки  $T_3(y)$  и  $T_4(y)$  совпадают, тогда нижнюю гарантированную оценку гамма-процентного остаточного ресурса  $T_\gamma(y)$  определим в соответствии с соотношением (8) из уравнения:

$$\frac{(m - t - y)^2}{(m_1 - t - y)^2 + m_2 - m_1^2} = \beta. \quad (10)$$

Выполнив необходимые преобразования уравнения (10), найдем нижнюю гарантированную оценку гамма-процентного остаточного ресурса оборудования

$$t_n = m_1 - y - \sqrt{\frac{\beta(m_2 - m_1^2)}{1 - \beta}} \quad \text{при } y \leq m_1 - \sqrt{\frac{\beta(m_2 - m_1^2)}{1 - \beta}}. \quad (11)$$

Аналогично для верхней гарантированной оценки гамма-процентного остаточного ресурса при двух моментах  $m_1, m_2$  в соответствии с работами [33, 34] имеем

$$\max_{F(t) \in F_0} P(t+y) = \frac{m_2 - m_1^2}{(m_1 - t - y)^2 + m_2 - m_1^2} \quad \text{при } t + y > m_1.$$

$$\min_{F(t) \in F_0} P(t) = \frac{(m_1 - y)^2}{(m_1 - y)^2 + m_2 - m_1^2} \quad \text{при } 0 < y \leq m_1.$$

Для определения верхней гарантированной оценки гамма-процентного остаточного ресурса получим следующее уравнение:

$$\frac{\frac{m_2 - m_1^2}{(m_1 - t - y)^2 + m_2 - m_1^2}}{\frac{(m_1 - y)^2}{(m_1 - y)^2 + m_2 - m_1^2}} = \beta,$$

решая которое найдем

$$t_v = m_1 - y + \sqrt{\frac{(m_2 - m_1^2) \left( 1 - \beta \frac{(m_1 - y)^2}{(m_1 - y)^2 + m_2 - m_1^2} \right)}{\beta \frac{(m_1 - y)^2}{(m_1 - y)^2 + m_2 - m_1^2}}} \quad (12)$$

верхнюю гарантированную оценку гамма-процентного остаточного ресурса оборудования при двух моментах  $m_1, m_2$ .

Выполнив соответствующие расчеты по соотношениям (11) и (12) при  $m_1 = 3,15 \cdot 10^5$  ч;  $m_2 = 1,47 \cdot 10^{11}$  ч<sup>2</sup>;  $\gamma = 50\%$ ;  $y = 3,15 \cdot 10^4$  ч, получим значения нижней и верхней гарантированных оценок гамма-процентного остаточного ресурса диска из дискового массива HP EVA P6500:  $t_n = 6,48 \cdot 10^4$  ч;  $t_v = 6,06 \cdot 10^5$  ч.

**Гарантированные оценки при различных значениях первого и второго моментов  $m_1$  и  $m_2$ .** В таблице приведены нижние и верхние гарантированные оценки гамма-процентного остаточного ресурса диска из дискового массива при различных значениях первого и второго моментов  $m_1$  и  $m_2$  времени безотказной работы близких к реальным.

Из таблицы видно, что при увеличении первого момента  $m_1$  времени безотказной работы диска наблюдается рост нижней гарантированной оценки гамма-про-

Таблица. Нижние и верхние гарантированные оценки гамма-процентного остаточного ресурса диска

Table. Lower and upper guaranteed estimates of gamma-percent the remaining disk resource

$m_1 \cdot 10^5$ , ч	$m_2 \cdot 10^{11}$ , ч <sup>2</sup>	$y \cdot 10^4$ , ч	$\beta$	$t_n \cdot 10^4$ , ч	$t_v \cdot 10^5$ , ч
3,15	1,47	3,15	0,5	6,48	6,06
3,20	1,47	3,20	0,5	7,77	5,90
3,23	1,47	3,23	0,5	8,49	5,82
3,25	1,47	3,25	0,5	8,99	5,76
3,28	1,47	3,28	0,5	9,75	5,68
3,30	1,47	3,30	0,5	10,3	5,62
3,33	1,47	3,33	0,5	11,1	5,53
3,35	1,47	3,35	0,5	11,6	5,48
3,40	1,47	3,40	0,5	13,0	5,33
3,40	1,48	3,40	0,5	12,6	5,40
3,40	1,49	3,40	0,5	12,5	5,43
3,40	1,49	3,40	0,5	12,3	5,45
3,40	1,50	3,40	0,5	12,2	5,48
3,40	1,50	3,40	0,5	12,1	5,50
3,40	1,55	3,40	0,5	10,8	5,75

центного остаточного ресурса диска и уменьшение верхней гамма-процентного остаточного ресурса диска при постоянном втором моменте  $m_2$ , а при увеличении второго момента  $m_2$  наблюдается противоположная тенденция.

В приведенном примере использованы два момента времени безотказной работы диска. При большем числе используемых моментов (большем, чем два) решение задачи определения гарантированных (нижних и верхних) оценок гамма-процентного остаточного ресурса возможно только численно.

### Заключение

Рассмотрена задача оценки показателя долговечности оборудования систем хранения данных — гамма-процентного остаточного ресурса в условиях неполных данных, представленных малыми выборками случайных величин времени безотказной работы обо-

рудования. Данная задача сформулирована как задача определения гарантированных (нижних и верхних) оценок гамма-процентного остаточного ресурса оборудования на множестве распределений времени безотказной работы с заданными моментами, равными моментам, найденным по имеющейся выборке времени безотказной работы, при решении этой задачи использованы результаты решения проблемы Маркова и неравенства между возможными экстремальными оценками гамма-процентного ресурса. Получены аналитические оценки гарантированного (нижнего и верхнего) гамма-процентного остаточного ресурса оборудования при двух используемых моментах.

Актуальность работы состоит в получении общего решения задачи определения гарантированного гамма-процентного остаточного ресурса оборудования систем хранения данных в условиях неполных данных, представленной малыми выборками наработок до отказа оборудования.

### Литература

- Глобальный кризис хранения данных. Почему места в хранилищах на всех не хватит [Электронный ресурс]. URL: <https://habr.com/ru/companies/first/articles/710838/> (дата обращения: 17.04.2024).
- Volume of data/information created, captured, copied, and consumed worldwide from 2010 to 2020, with forecasts from 2021 to 2025 [Электронный ресурс]. URL: <https://www.statista.com/statistics/871513/worldwide-data-created/> (дата обращения: 17.04.2024).
- Фарли М. Сети хранения данных / 2-е изд. М.: Лори, 2004. 576 с.
- Иваничкова Л.В. Математические модели надежности и методы ее повышения в современных распределенных отказоустойчивых системах хранения данных: диссертация на соискание ученой степени кандидата технических наук. М.: МФТИ, 2018. 114 с.
- Poyanova E.D., Tatarnikova T.M. Models and methods for studying network traffic // Proc. of the Wave Electronics and its Application in Information and Telecommunication Systems (WECONF). 2018. P. 1–5. <https://doi.org/10.1109/weconf.2018.8604470>

### References

- The global data storage crisis. Why is there not enough storage space for everyone? Available at: <https://habr.com/ru/companies/first/articles/710838/> (accessed: 17.04.2024). (in Russian)
- Volume of data/information created, captured, copied, and consumed worldwide from 2010 to 2020, with forecasts from 2021 to 2025. Available at: <https://www.statista.com/statistics/871513/worldwide-data-created/> (accessed: 17.04.2024).
- Farley M. Building Storage Networks. McGraw Hill, 2001, 656 p.
- Ivanichkina L.V. Mathematical Models of Reliability and Methods for Its Improvement in Modern Distributed Fault-Tolerant Data Storage Systems. Moscow, MFTI, 2018, 114 p. (in Russian)
- Poyanova E.D., Tatarnikova T.M. Models and methods for studying network traffic. Proc. of the Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), 2018, pp. 1–5. <https://doi.org/10.1109/weconf.2018.8604470>
- Sovetov B.Ya., Tatarnikova T.M., Poyanova E.D. Organization of multi-level data storage. Information and Control Systems, 2019,

6. Советов Б.Я., Татарникова Т.М., Пойманова Е.Д. Организация многоуровневого хранения данных // Информационно-управляющие системы. 2019. № 2(99). С. 68–75. <https://doi.org/10.31799/1684-8853-2019-2-68-75>
7. Tatarnikova T.M., Poymanova E.D. Energy model of data storage process // Proc. of the Wave Electronics and its Application in Information and Telecommunication Systems (WECONF). 2019. P. 1–4. <https://doi.org/10.1109/WECONF.2019.8840111>
8. Poymanova E.D., Tatarnikova T.M. Tiered data storage model // Proc. of the Wave Electronics and its Application in Information and Telecommunication Systems (WECONF). 2019. P. 1–4. <https://doi.org/10.1109/weconf.2019.8840589>
9. Sovetov B.Ya., Tatarnikova T.M., Poymanova E.D. Storage scaling management mode // Информационно-управляющие системы. 2020. № 5(108). С. 43–49. <https://doi.org/10.31799/1684-8853-2020-5-43-49>
10. Крылов Д.Р., Пойманова Е.Д., Тюрликов А.М. Модель реплицируемой системы хранения данных с использованием среднего возраста информации в качестве показателя актуальности данных // Информационно-управляющие системы. 2024. № 3(130). С. 11–23. <https://doi.org/10.31799/1684-8853-2024-3-11-23>
11. Богатырев В.А., Богатырев С.В., Богатырев А.В. Оценка готовности компьютерной системы к своевременному обслуживанию запросов при его совмещении с информационным восстановлением памяти после отказов // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 3. С. 608–617. <https://doi.org/10.17586/2226-1494-2023-23-3-608-617>
12. Татарникова Т.М., Пойманова Е.Д. Модель многоуровневой системы хранения данных // Научно-технический вестник информационных технологий, механики и оптики. 2019. Т. 19. № 2. С. 271–279. <https://doi.org/10.17586/2226-1494-2019-19-2-271-279>
13. Татарникова Т.М., Пойманова Е.Д. Методика дифференцированного наращивания емкости системы хранения данных с многоуровневой структурой // Научно-технический вестник информационных технологий, механики и оптики. 2020. Т. 20. № 1. С. 66–73. <https://doi.org/10.17586/2226-1494-2020-20-1-66-73>
14. Рахман П.А., Каюшев А.И., Шарипов М.И. Модели надежности отказоустойчивых систем хранения данных // Вестник УГАТУ. 2015. Т. 19. № 1(67). С. 155–166.
15. Каюшев А.И., Рахман П.А., Шарипов М.И. Анализ показателей надежности двухуровневых магистральных сетей // Вестник УГАТУ. 2014. Т. 18. № 2(63). С. 197–207.
16. Rakhman P.A., Muraveva E.A., Sharipov M.I. Reliability model of fault-tolerant dual-disk redundant array // Key Engineering Materials. 2016. V. 685. P. 805–810. <https://doi.org/10.4028/www.scientific.net/kem.685.805>
17. Shooman M.L. Reliability of Computer Systems and Networks: Fault Tolerance, Analysis, and Design. John Wiley & Sons Inc., 2002. 552 p.
18. Elerath J.G. Reliability model and assessment of redundant arrays of inexpensive disks (RAID) incorporating latent defects and non-homogeneous Poisson process events: PhD dissertation. University of Maryland, 2007.
19. Пономарев В.А. Моделирование и оптимизация функционирования твердотельной системы хранения данных: диссертация на соискание ученой степени кандидата технических наук. Петрозаводск: ПетрГУ, 2019. 190 с.
20. Rumyantsev A., Ivashko E., Chernov I., Kositsyn D., Shabaev A., Ponomarev V. Latency/Wearout in a flash-based storage system with replication on write // Proc. of the 24<sup>th</sup> Conference of Open Innovations Association (FRUCT). 2019. P. 360–366. <https://doi.org/10.23919/fruct.2019.8711984>
21. Атрощенко В.А., Тымчук А.И. К вопросу выбора наилучшего уровня RAID для хранилищ данных информационной системы, обеспечивающей быструю обработку больших данных // Современные научно-исследовательские технологии. 2007. № 4. С. 12–16.
22. Гуз И.Д., Острейковский В.А. Анализ эксплуатационной надежности оборудования систем хранения данных // Вестник кибернетики. 2019. № 3(35). С. 35–42. <https://doi.org/10.34822/1999-7604-2019-3-35-42>
23. Nelub V., Gantimurov A., Borodulin A. Economic analysis of data protection in systems with complex architecture using neural network methods // Economic Annals-XXI. 2020. V. 185. N 9-10. P. 178–188. <https://doi.org/10.21003/ea.v185-17>
24. Gantimurov A.P. Analysis and synthesis of the distributed data storage systems. Dissertation for the degree of candidate of technical sciences. Moscow, BMSTU, 2022, 94 p. (in Russian)
25. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Reliability and timeliness of servicing requests in infocommunication systems, taking no. 2(99), pp. 68–75. (in Russian). <https://doi.org/10.31799/1684-8853-2019-2-68-75>
7. Tatarnikova T.M., Poymanova E.D. Energy model of data storage process. Proc. of the Wave Electronics and its Application in Information and Telecommunication Systems (WECONF). 2019, pp. 1–4. <https://doi.org/10.1109/WECONF.2019.8840111>
8. Poymanova E.D., Tatarnikova T.M. Tiered data storage model. Proc. of the Wave Electronics and its Application in Information and Telecommunication Systems (WECONF). 2019, pp. 1–4. <https://doi.org/10.1109/weconf.2019.8840589>
9. Sovietov B.Ya., Tatarnikova T.M., Poymanova E.D. Storage scaling management mode. Information and Control Systems, 2020, no. 5(108), pp. 43–49. <https://doi.org/10.31799/1684-8853-2020-5-43-49>
10. Krylov D.R., Poymanova E.D., Turlikov A.M. Modeling a replicated storage system with the use of the average age of information as an indicator of data relevance. Information and Control Systems, 2024, no. 3(130), pp. 11–23. (in Russian). <https://doi.org/10.31799/1684-8853-2024-3-11-23>
11. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Assessment of the readiness of a computer system for timely servicing of requests when combined with information recovery of memory after failures. Scientific and Technical Journal of Information Technologies, Mechanics and Optics, 2023, vol. 23, no. 3, pp. 608–617. (in Russian). <https://doi.org/10.17586/2226-1494-2023-23-3-608-617>
12. Tatarnikova T.M., Poymanova E.D. Model of multi-level data storage system. Scientific and Technical Journal of Information Technologies, Mechanics and Optics, 2019, vol. 19, no. 2, pp. 271–279. (in Russian). <https://doi.org/10.17586/2226-1494-2019-19-2-271-279>
13. Tatarnikova T.M., Poymanova E.D. Differentiated capacity extension method for system of data storage with multilevel structure. Scientific and Technical Journal of Information Technologies, Mechanics and Optics, 2020, vol. 20, no. 1, pp. 66–73. (in Russian). <https://doi.org/10.17586/2226-1494-2020-20-1-66-73>
14. Rahman P.A., Kayashev A.I., Sharipov M.I. Reliability models of the fault-tolerant storage systems. Vestnik UGATU, 2015, vol. 19, no. 1(67), pp. 155–166. (in Russian)
15. Kayashev A.I., Rahman P.A., Sharipov M.I. Reliability analysis of two-level backbone networks. Vestnik UGATU, 2014, vol. 18, no. 2(63), pp. 197–207. (in Russian)
16. Rakhman P.A., Muraveva E.A., Sharipov M.I. Reliability model of fault-tolerant dual-disk redundant array. Key Engineering Materials, 2016, vol. 685, pp. 805–810. <https://doi.org/10.4028/www.scientific.net/kem.685.805>
17. Shooman M.L. Reliability of Computer Systems and Networks: Fault Tolerance, Analysis, and Design. John Wiley & Sons Inc., 2002, 552 p.
18. Elerath J.G. Reliability model and assessment of redundant arrays of inexpensive disks (RAID) incorporating latent defects and non-homogeneous Poisson process events. PhD dissertation, University of Maryland, 2007.
19. Ponomarev V.A. Modeling and optimization of solid-state data storage system functioning. Dissertation for the degree of candidate of technical sciences. Petrozavodsk, PetrSU, 2019, 190 p. (in Russian)
20. Rumyantsev A., Ivashko E., Chernov I., Kositsyn D., Shabaev A., Ponomarev V. Latency/Wearout in a flash-based storage system with replication on write. Proc. of the 24<sup>th</sup> Conference of Open Innovations Association (FRUCT). 2019, pp. 360–366. <https://doi.org/10.23919/fruct.2019.8711984>
21. Atroschenko V.A., Tymchuk A.I. On the question of choosing the best raid level for data storages of the information system that provides fast processing of big data. Modern high technologies, 2007, no. 4, pp. 12–16. (in Russian)
22. Guz I.D., Ostrikovsky V.A. Operational reliability analysis of hardware of data storage systems. Proceedings in Cybernetics, 2019, no. 3(35), pp. 35–42. (in Russian). <https://doi.org/10.34822/1999-7604-2019-3-35-42>
23. Nelub V., Gantimurov A., Borodulin A. Economic analysis of data protection in systems with complex architecture using neural network methods. Economic Annals-XXI. 2020, vol. 185, no. 9-10, pp. 178–188. <https://doi.org/10.21003/ea.v185-17>
24. Gantimurov A.P. Analysis and synthesis of the distributed data storage systems. Dissertation for the degree of candidate of technical sciences. Moscow, BMSTU, 2022, 94 p. (in Russian)
25. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Reliability and timeliness of servicing requests in infocommunication systems, taking

- кандидата технических наук. М.: МГТУ им. Н.Э. Баумана, 2022. 94 с.
25. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Reliability and timeliness of servicing requests in infocommunication systems, taking into account the physical and information recovery of redundant storage devices // Proc. of the International Conference on Information, Control, and Communication Technologies (ICCT). 2022. Р. 1–4. <https://doi.org/10.1109/icct56057.2022.9976800>
26. Фунг В.К., Богатырев В.А., Кармановский Н.С., Лэ В.Х. Оценка вероятностно-временных характеристик компьютерной системы с контейнерной виртуализацией // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24. № 2. С. 249–255. <https://doi.org/10.17586/2226-1494-2024-24-2-249-255>
27. Садыхов Г.С., Савченко В.П., Елисеева О.В. Основы оценок остаточного ресурса изделий // Вестник МГТУ им. Н.Э. Баумана. Сер. Естественные науки. 2011. № S3. С. 83–99.
28. Савченко В.П., Садыхов Г.С., Кузнецов В.И. Новая методология сверхсрочной безопасной эксплуатации технических объектов // Петербургский журнал электроники. 2004. № 3-4. С. 184–188.
29. Соколов С.В. Оценка остаточного ресурса подсистем СУЗ реактора РБМК-1000 первого блока Смоленской АЭС // Известия вузов. Ядерная энергетика. 2009. № 3. С. 37–43.
30. Байхельт Ф., Франкен П. Надёжность и техническое обслуживание. Математический подход. М.: Радио и связь, 1988. 390 с.
31. Ломакин М.И., Ниязова Ю.М., Смекалов Д.Г. Оценка моментов остаточного времени функционирования производственной системы // Надёжность и долговечность машин и механизмов: сборник материалов XV Всероссийской научно-практической конференции. 2024. С. 155–158.
32. Ломакин М.И., Докукин А.В., Мошков В.Б., Олтян И.Ю., Ниязова Ю.М., Смекалов Д.Г. Гарантированные оценки остаточного среднего времени развития чрезвычайной ситуации // Технологии гражданской безопасности. 2024. Т. 21. № 1(79). С. 45–49.
33. Ломакин М.И. Гарантированные оценки вероятности безотказной работы в классе распределений с фиксированными моментами // Автоматика и телемеханика. 1991. № 1. С. 154–161.
34. Lomakin M., Buryi A., Dokukin A., Strekha A., Niyazova J., Balvanovich A. Estimation of quality indicators based on sequential measurements analysis // International Journal for Quality Research. 2020. V. 41. N 1. P. 147–162. <https://doi.org/10.24874/ijqr14.01-10>
35. Ломакин М.И., Докукин А.В. Оценка моментов квантованной случайной величины // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 3. С. 646–651. <https://doi.org/10.17586/2226-1494-2023-23-3-646-651>
36. HP EVA P6500 / P6550 STORAGE (QK720A) [Электронный ресурс]. URL: [https://www.karmaroup.ru/catalog/snyatye-s-proizvodstva-skhd-hpe/hp\\_eva\\_p6550/?ysclid=lyzu635lga642184594](https://www.karmaroup.ru/catalog/snyatye-s-proizvodstva-skhd-hpe/hp_eva_p6550/?ysclid=lyzu635lga642184594) (дата обращения: 17.04.2024).
- into account the physical and information recovery of redundant storage devices. *Proc. of the International Conference on Information, Control, and Communication Technologies (ICCT)*, 2022, pp. 1–4. <https://doi.org/10.1109/icct56057.2022.9976800>
26. Phung V.Q., Bogatyrev V.F., Karmanovskiy N.S., Le V.H. Evaluation of probabilistic-temporal characteristics of a computer system with container virtualization. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 2, pp. 249–255. (in Russian). <https://doi.org/10.17586/2226-1494-2024-24-2-249-255>
27. Sadykhov G.S., Savchenko V.P., Eliseeva O.V. Basics of estimating residual life of products. *Herald of the Bauman Moscow State Technical University. Series Natural Sciences*, 2011, no. S3, pp. 83–99. (in Russian)
28. Savchenko V.P., Sadykhov G.S., Kuznetcov V.I. New methodology for ultra-urgent safe operation of the technical objects. *Petersburg Electronics Journal*, 2004, no. 3-4, pp. 184–188. (in Russian)
29. Sokolov S.V. The residual lifetime estimation for the RBMK-1000 PCS of the Smolensk NPP'S first power unit. *Izvestiya vuzov. Yadernaya Energetika*, 2009, no. 3, pp. 37–43. (in Russian)
30. Beichelt F., Franken P. *Zuverlässigkeit und Instandhaltung*. Hanser, 1984, 315 p.
31. Lomakin M.I., Niyazova YU.M., Smekalov D.G. Evaluation of the moments of the remaining operating time of the production system. *Machines and mechanisms reliability and durability collection of materials of the XI<sup>th</sup> all-Russia scientific and practical conference*, 2024, pp. 155–158. (in Russian)
32. Lomakin M.I., Dokukin A.V., Moskrov V.B., Oltyan I.Yu., Niyazova Ju.M., Smekalov D.G. Guaranteed assessments of emergency development remaining average time. *Civil Security Technology*, 2024, vol. 21, no. 1(79), pp. 45–49. (in Russian)
33. Lomakin M.I. Guaranteed estimates of the probability of failure-free operation in a class of distributions with fixed moments. *Avtomatika i telemekhanika*, 1991, vol. 1, pp. 154–161. (in Russian)
34. Lomakin M., Buryi A., Dokukin A., Strekha A., Niyazova J., Balvanovich A. Estimation of quality indicators based on sequential measurements analysis. *International Journal for Quality Research*, 2020, vol. 41, no. 1, pp. 147–162. <https://doi.org/10.24874/ijqr14.01-10>
35. Lomakin M.I., Dokukin A.V. Estimation of the moments of a quantized random variable. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2023, vol. 23, no. 3, pp. 646–651. (in Russian). <https://doi.org/10.17586/2226-1494-2023-23-3-646-651>
36. HP EVA P6500 / P6550 STORAGE (QK720A). Available at: [https://www.karmaroup.ru/catalog/snyatye-s-proizvodstva-skhd-hpe/hp\\_eva\\_p6550/?ysclid=lyzu635lga642184594](https://www.karmaroup.ru/catalog/snyatye-s-proizvodstva-skhd-hpe/hp_eva_p6550/?ysclid=lyzu635lga642184594) (accessed: 17.04.2024).

## Авторы

**Ломакин Михаил Иванович** — доктор технических наук, доктор экономических наук, профессор, главный научный сотрудник, Всероссийский научно-исследовательский институт по проблемам гражданской обороны и чрезвычайных ситуаций МЧС России, Москва, 121352, Российская Федерация, [sc 7003352786](#), <https://orcid.org/0000-0003-4191-1348>, lomakin@vniigochs.ru

**Докукин Александр Владимирович** — доктор экономических наук, главный научный сотрудник, Всероссийский научно-исследовательский институт по проблемам гражданской обороны и чрезвычайных ситуаций МЧС России, Москва, 121352, Российская Федерация, [sc 56161047500](#), <https://orcid.org/0000-0002-3342-8770>, dokukin@vniigochs.ru

**Олтян Ирина Юрьевна** — кандидат технических наук, ученый секретарь, Всероссийский научно-исследовательский институт по проблемам гражданской обороны и чрезвычайных ситуаций МЧС России, Москва, 121352, Российская Федерация, [sc 57190430695](#), <https://orcid.org/0000-0002-2178-5033>, oltyan@vniigochs.ru

**Ниязова Юлия Михайловна** — кандидат экономических наук, доцент, Московский государственный университет геодезии и картографии, Москва, 105064, Российская Федерация, <https://orcid.org/0000-0001-5589-4855>, y\_niyazova@edu.miigaik.ru

## Authors

**Mikhail I. Lomakin** — D.Sc., D.Sc. (Economics), Professor, Chief Researcher, All-Russian Scientific Research Institute for Civil Defense and Emergencies of the EMERCOM of Russia, Moscow, 121352, Russian Federation, [sc 7003352786](#), <https://orcid.org/0000-0003-4191-1348>, lomakin@vniigochs.ru

**Alexander V. Dokukin** — D.Sc. (Economics), Chief Researcher, All-Russian Scientific Research Institute for Civil Defense and Emergencies of the EMERCOM of Russia, Moscow, 121352, Russian Federation, [sc 56161047500](#), <https://orcid.org/0000-0002-3342-8770>, dokukin@vniigochs.ru

**Irina Yu. Oltyan** — PhD, Scientific Secretary, All-Russian Scientific Research Institute for Civil Defense and Emergencies of the EMERCOM of Russia, Moscow, 121352, Russian Federation, [sc 57190430695](#), <https://orcid.org/0000-0002-2178-5033>, oltyan@vniigochs.ru

**Yulia M. Niyazova** — PhD (Economics), Associate Professor, Moscow State University of Geodesy and Cartography, Moscow, 105064, Russian Federation, <https://orcid.org/0000-0001-5589-4855>, y\_niyazova@edu.miigaik.ru

doi: 10.17586/2226-1494-2024-24-5-824-833

## Classification of multiple sclerosis lesion through Deep Learning analysis of MRI images

**Mathavan Divya<sup>1✉</sup>, Jayeseelan Dhilipan<sup>2</sup>, Appu Saravanan<sup>3</sup>**

<sup>1,2</sup> SRM Institute of Science and Technology, Ramapuram Campus, Chennai, 600089, India

<sup>3</sup> Easwari Engineering College, Ramapuram Campus, Chennai, 600089, India

<sup>1</sup> divyam1@srmist.edu.in✉, <https://orcid.org/0000-0002-9960-8061>

<sup>2</sup> hod.mca.rmp@srmist.edu.in, <https://orcid.org/0000-0003-2122-5076>

<sup>3</sup> dean.academic@srmrmp.edu.in, <https://orcid.org/0000-0003-2093-900X>

## Abstract

Multiple Sclerosis (MS) is a progressive autoimmune disease affecting the central nervous system, causing communication disruptions between the brain and the body. Early and accurate detection of MS lesions in brain Magnetic Resonance Imaging (MRI) scans is crucial for effective treatment. This paper proposes MSNet, a deep learning-based approach for automatic detection and diagnosis of MS lesions from MRI images, leveraging Convolutional Neural Networks (CNNs) for precise lesion identification and classification. Our methodology involves a comprehensive analysis of MRI datasets, including preprocessing steps such as normalization and lesion segmentation. We propose a novel CNN architecture tailored for MS lesion detection, achieving an accuracy rate of 98.2 % on the test dataset. By incorporating advanced image recognition techniques, our system classifies MS lesions from diverse brain pathologies present in MRI images. The model also highlights MS lesions within the MRI images, aiding neuroradiologists in accurate diagnosis and treatment planning. This study contributes significantly to improving MS diagnosis by providing a reliable and automated tool for lesion detection and classification.

## Keywords

**Keywords** multiple sclerosis, machine learning, MRI

**For citation:** Divya M., Dhilipan J., Saravanan A. Classification of multiple sclerosis lesion through Deep Learning analysis of MRI images. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 824–833. doi: 10.17586/2226-1494-2024-24-5-824-833

УЛК 004.89

## Классификация поражений рассеянным склерозом посредством анализа изображений магнитно-резонансной томографии методом глубокого обучения

Матаван Дивья<sup>1</sup>✉, Джасиран Дхирипанд<sup>2</sup>, Аппу Сараванан<sup>3</sup>

<sup>1,2</sup> Институт науки и технологий SRM, Кампус Рамапурам, Ченнаи, 600089, Индия

<sup>3</sup> Инженерный колледж Иасвари, Кампус Рамапурам, Ченнаи, 600089, Индия

<sup>1</sup> divyam1@srmist.edu.in  <https://orcid.org/0000-0002-9960-8061>

<sup>2</sup> hod mca rmp@srmist.edu.in <https://orcid.org/0000-0003-2122-5076>

<sup>3</sup> dean.academic@srmrmp.edu.in, <https://orcid.org/0000-0003-2093-900X>

## Аннотация

**Аннотация**  
Рассеянный склероз (РС) представляет собой прогрессирующее аутоиммунное заболевание, поражающее центральную нервную систему. Раннее и точное обнаружение поражений РС на снимках магнитно-резонансной томографии (МРТ) головного мозга имеет решающее значение для эффективного лечения. В работе предлагается классификация на основе глубокого обучения для автоматического обнаружения и диагностики поражений РС на снимках МРТ, использующий сверточные нейронные сети (Convolutional Neural Network, CNNs) для точной идентификации и классификации поражений. Классификация включает в себя всесторонний анализ наборов

---

© Divya M., Dhilipan J., Saravanan A., 2024

данных МРТ и этапы их предварительной обработки, такие как нормализация и сегментация поражений. Предложенная архитектура CNN, разработанная для обнаружения поражений РС, достигает точности 98,2 % на тестовом наборе данных. Благодаря внедрению передовых методов распознавания изображений, представленный метод глубокого обучения классифицирует поражения РС среди различных патологий мозга, присутствующих на снимках МРТ. Метод выделяет поражения РС на снимках МРТ, помогая нейрорадиологам в точной диагностике и планировании лечения. Исследование вносит вклад в улучшение диагностики РС, предоставляя надежный и автоматизированный инструмент обнаружения и классификации поражений.

#### Ключевые слова

рассеянный склероз, машинное обучение, МРТ

**Ссылка для цитирования:** Дивья М., Дхилипан Дж., Сараванан А. Классификация поражений рассеянным склерозом посредством анализа изображений магнитно-резонансной томографии методом глубокого обучения // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 824–833 (на англ. яз.). doi: 10.17586/2226-1494-2024-24-5-824-833

## Introduction

Multiple Sclerosis (MS) is a chronic autoimmune disease that affects the Central Nervous System (CNS), leading to various neurological symptoms and disabilities. The hallmark of MS pathology is the immune-mediated attack on the myelin sheath, the protective covering of nerve fibers in the CNS. This demyelination process disrupts the transmission of nerve signals, causing a wide range of symptoms, such as vision impairment, muscle weakness, coordination difficulties, fatigue, and cognitive dysfunction [1–3]. The disease unpredictable nature, characterized by periods of relapse and remission or steady progression, poses significant challenges for both patients and healthcare providers. Early and accurate detection of MS lesions in Magnetic Resonance Imaging (MRI) scans plays a pivotal role in disease management, treatment planning, and prognostication [4–6]. MRI has become a cornerstone imaging modality for assessing MS-related lesions in the brain and spinal cord. The high spatial resolution and tissue contrast provided by MRI allow clinicians to visualize MS lesions which appear as hyperintense areas on T2-weighted and Fluid-Attenuated Inversion Recovery (FLAIR) sequences. Lesions are typically distributed in periventricular, juxtacortical, infratentorial, and spinal cord regions, reflecting the multifocal nature of MS pathology. However, manually identifying and quantifying MS lesions in MRI scans are time-consuming tasks prone to inter-observer variability and subjective interpretations among radiologists. Traditional methods rely heavily on visual inspection and semi-automated segmentation tools which may not capture subtle or small lesions accurately, especially in early disease stages or in regions with complex anatomical structures [7, 8]. These challenges underscore the need for advanced computational approaches, particularly deep learning techniques, to enhance the accuracy, efficiency, and objectivity of MS lesion detection and classification in MRI images. Deep learning represents a subset of Artificial Intelligence (AI) that mimics the human brain neural networks to automatically learn and extract intricate patterns and features from large datasets. Convolutional Neural Networks (CNNs), a prominent deep learning architecture, have demonstrated remarkable success in various image analysis tasks, including medical image segmentation, classification, and anomaly detection. By leveraging CNNs and related deep learning models, researchers

and clinicians aim to revolutionize MS diagnosis and monitoring paradigms, paving the way for personalized treatment strategies and improved patient outcomes. The integration of deep learning techniques into MS lesion analysis offers several advantages over traditional methods. Firstly, deep learning models can process vast amounts of MRI data rapidly and consistently, reducing the time and labor required for lesion identification and quantification. This scalability is particularly advantageous in large-scale studies involving multiple patients or longitudinal assessments. Secondly, deep learning algorithms can learn complex spatial and textural features from MRI images, capturing subtle lesion patterns and variations that may be missed by human observers or conventional algorithms. This capability is crucial for detecting early-stage lesions, differentiating between MS lesion subtypes (such as active, chronic, or enhancing lesions), and assessing lesion progression over time. Despite these advancements, challenges persist in deploying deep learning models in clinical practice. Model interpretability, generalizability across diverse patient populations, data privacy concerns, and regulatory considerations are among the key hurdles that researchers and healthcare stakeholders must address. Collaborative efforts between data scientists, clinicians, regulatory bodies, and industry partners are essential to validate and translate deep learning solutions into robust clinical tools that enhance MS care delivery and outcomes. In this context, this paper proposes a novel deep learning-based approach for automated detection, segmentation, and classification of MS lesions in MRI images. Leveraging state-of-the-art CNN architectures and advanced image processing techniques, our methodology aims to overcome existing limitations in MS lesion analysis, offering accurate, efficient, and clinically relevant solutions for MS diagnosis and management. We present a detailed analysis of our deep learning model performance, including accuracy rates, sensitivity, specificity, and comparative evaluations against traditional methods or benchmark datasets.

## Literature Review

The literature on MS lesion detection and classification using MRI and machine learning techniques has witnessed significant advancements in recent years. Several studies have focused on enhancing the accuracy, efficiency, and clinical relevance of MS lesion analysis, addressing challenges in distinguishing MS lesions from other brain

pathologies and leveraging deep learning methodologies for improved diagnostic outcomes. Zhang et al. (2019) [9], while successful in predicting conversion from clinically isolated syndrome to MS using imaging-based machine learning, faced challenges in generalizing their model across diverse patient populations and capturing nuanced lesion characteristics critical for differential diagnosis. Rezaee et al. (2020) [10] introduced a supervised meta-heuristic extreme learning machine for MS detection based on multiple feature descriptors, yet the approach reliance on handcrafted features limited its adaptability to complex lesion patterns and evolving disease states. Ekşioğlu et al. (2021) [11] and Peng et al. (2021) [12] made strides in differentiating MS lesions from brain tumors and predicting lesion evolution, respectively. However, their studies primarily focused on specific lesion subtypes or disease stages, overlooking the holistic characterization and early-stage detection crucial for comprehensive MS management. Eshaghi et al. (2021) [13] leveraged unsupervised machine learning for MS subtype identification, yet the lack of interpretability and clinical validation hindered direct translation into actionable clinical insights and personalized treatment strategies. The studies by Bonanno et al. (2021) [14], Iswisi et al. (2021) [15], Jain et al. (2022) [16], and Garcia-Martin et al. (2021) [17] explored various machine learning algorithms and imaging modalities for MS diagnosis and lesion detection. Still, limitations in scalability, model interpretability, and comparative performance analysis across diverse datasets and clinical scenarios necessitated further refinement and validation. Montolio et al. (2022) [18] emphasized the role of Optical Coherence Tomography (OCT) and machine learning in MS and optic neuritis diagnosis. However, challenges in integrating OCT data with comprehensive MRI-based lesion analysis and addressing data heterogeneity remained as areas requiring attention.

## Methodology

The methodology for data collection and preprocessing of MRI datasets in this study aimed to ensure high-quality input data for subsequent deep learning model development and evaluation. The following detailed steps were followed.

### Data Sources

MRI datasets were collected from Open Access Series of Imaging Studies (OASIS-MS) and collaborating medical institutions specializing in MS research. This approach ensured access to a diverse range of MS patient scans, covering different disease stages and lesion characteristics.

### MRI Acquisition Parameters

**Field Strength.** All MRI scans were conducted using standardized field strength of 3 Tesla to maintain imaging consistency across datasets.

**Imaging Sequences.** T1-weighted, T2-weighted, and FLAIR sequences were used to capture various tissue contrasts and lesion features relevant to MS diagnosis.

**Voxel Size.** MRI images were acquired with a standardized voxel size of  $1 \times 1 \times 1$  mm, ensuring consistent spatial resolution for accurate lesion analysis.

**MRI Machine Manufacturers.** Scans were acquired using MRI machines from leading manufacturers, such as

Siemens, GE Healthcare, and Philips, although specific models were not disclosed.

### Preprocessing Steps

**Image Normalization.** Intensity normalization techniques were applied across MRI sequences to standardize intensity values and reduce variability due to scanner settings or acquisition conditions.

**Brain Extraction.** Non-brain tissues, including skull and scalp, were automatically removed using robust brain extraction algorithms. This step ensured that subsequent analyses focused exclusively on relevant brain regions.

**Lesion Segmentation.** Automated segmentation algorithms such as CNNs and region-based methods were employed to delineate brain regions and identify potential MS lesions. These algorithms utilized intensity thresholds and spatial information to segment lesion areas accurately without manual intervention.

## The Proposed MSNet

The proposed method, named MSNet, is a framework customized specifically for MS lesion detection and classification using MRI images. MSNet leverages spatial and contextual features within MRI scans to accurately identify and categorize MS lesions.

### Input Layer

The input layer of MSNet accepts multi-sequence MRI inputs with standardized dimensions and intensity values. This design choice enables the model to process information from different MRI sequences simultaneously, providing a comprehensive view of the brain structural and tissue characteristics relevant to MS lesion detection.

### Convolutional Layers

MSNet is built with multiple convolutional layers that employ varying filter sizes. These layers are pivotal in extracting hierarchical features that capture spatial information crucial for identifying MS lesion patterns within MRI images. The convolutional layers generate feature maps that highlight significant spatial features, aiding in lesion localization and characterization.

### Activation Functions

Rectified Linear Units (ReLU) serve as the activation functions within MSNet. ReLU introduces non-linearity into the model, enhancing its capacity to learn intricate patterns present in MRI data. This non-linear activation function is particularly effective in capturing subtle variations indicative of MS lesions, contributing to the model discriminative power.

### Pooling Layers

Max-pooling operations are applied strategically within MSNet to downscale feature maps generated by convolutional layers. This downsampling technique reduces computational complexity while retaining essential spatial information relevant to MS lesions. Max-pooling helps in preserving key features while abstracting higher-level representations, improving the model efficiency and generalization ability.

### Batch Normalization

To enhance model convergence and stability during training, batch normalization is integrated into MSNet. This technique normalizes activations within mini-

batches, mitigating issues related to internal covariate shift and accelerating training convergence. By maintaining consistent activations across layers, batch normalization aids in smoother gradient flow and faster training iterations.

### Fully Connected Layers

MSNet incorporates dense fully connected layers responsible for feature aggregation and classification. These layers consolidate extracted features from convolutional layers and enable the model to learn complex relationships within the MRI data. Dropout regularization is applied within these fully connected layers to prevent overfitting by randomly deactivating neurons during training, promoting better generalization to unseen data.

### Output Layer

The output layer of MSNet utilizes a Softmax activation function tailored for multi-class classification tasks. In the context of MS lesion detection and classification, the Softmax layer assigns probability scores to different lesion categories or disease subtypes. This probabilistic output facilitates accurate lesion classification, aiding clinicians

in diagnosis and treatment planning for MS patients. Fig. 1 shows the proposed architecture.

During model training, MSNet utilizes the Categorical Cross-Entropy (CE) loss function which is well-suited for multi-class classification tasks such as MS lesion detection and classification. The CE loss function is defined as

$$CE\ Loss = - \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(p_{i,c}),$$

where  $N$  is the number of samples;  $C$  is the number of classes;  $y_{i,c}$  is the ground truth label for sample  $i$  and class  $c$ ;  $p_{i,c}$  is the predicted probability of sample  $i$  belonging to class  $c$ .

The CE loss penalizes deviations between predicted probabilities and ground truth labels, guiding the network to learn accurate representations of MS lesion patterns.

### Optimizer

The Adam optimizer is chosen for training MSNet due to its efficiency in navigating the model parameter space. Adam combines adaptive learning rates and momentum

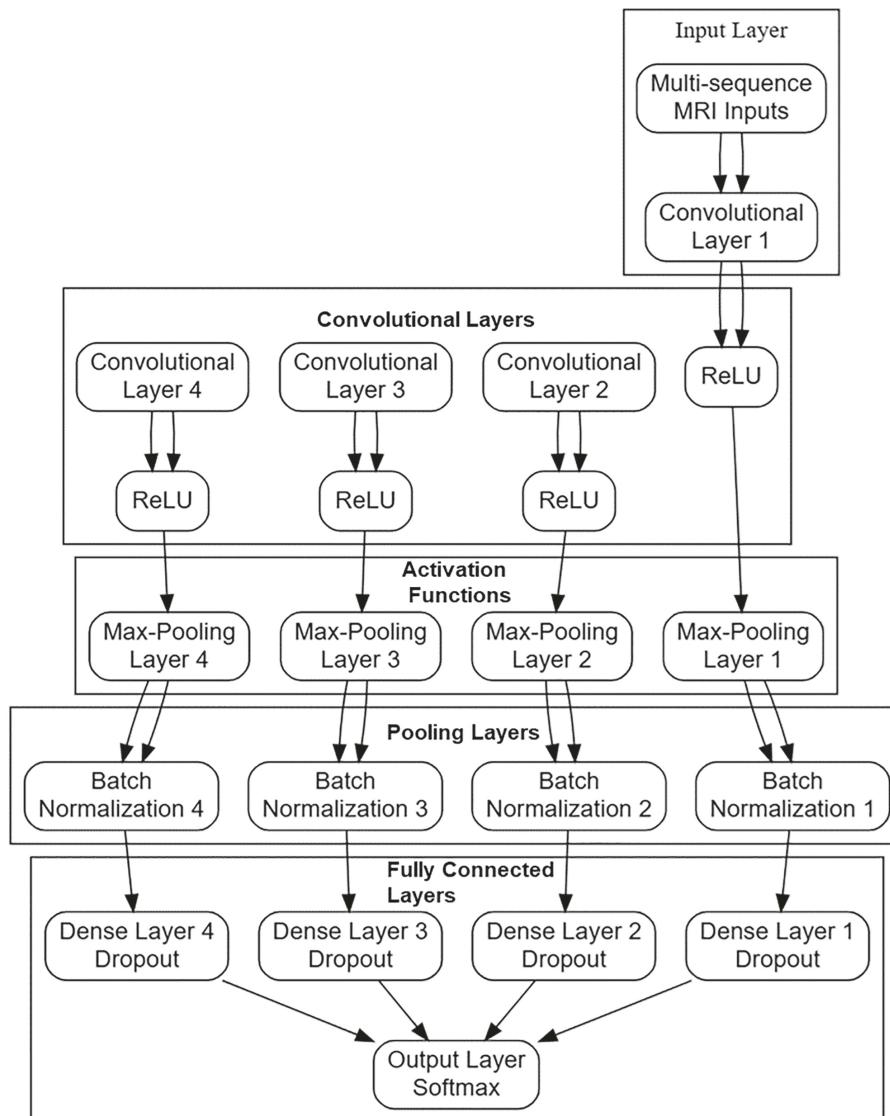


Fig. 1. Proposed architecture

methods leading to faster convergence during training. The Adam update rule is given by:

$$\begin{aligned} m_t &= \beta_1 \times m_{t-1} + (1 - \beta_1) \times g_t, \\ v_t &= \beta_2 \times v_{t-1} + (1 - \beta_2) \times g_t^2, \\ \hat{m}_t &= \frac{m_t}{1 - \beta_1^t}, \\ \hat{v}_t &= \frac{v_t}{1 - \beta_2^t}, \\ \theta_t &= \theta_{t-1} - \frac{lr \cdot \hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon}, \end{aligned}$$

where  $m_t$  and  $v_t$  are the first and second moments of gradients respectively;  $\beta_1$  and  $\beta_2$  are decay rates for moments;  $\theta_t$  are the model parameters at time step  $t$ ;  $g_t$  are gradients at time step  $t$ ;  $lr$  is the learning rate;  $\epsilon$  is a small constant to prevent division by zero.

#### Learning Rate Scheduling

To prevent overfitting and ensure optimal model training, MSNet implements adaptive learning rate strategies based on validation performance. Learning rates are adjusted dynamically during training epochs, with decreases triggered by stagnation in validation metrics. This approach helps the model converge to a robust solution while avoiding excessive parameter updates that may lead to overfitting.

#### Data Augmentation

Image augmentation techniques play a crucial role in enhancing dataset diversity and improving the model generalization ability. MSNet applies augmentation methods such as rotation, flipping, and scaling to artificially expand the training dataset. By introducing variations in image orientation, perspective, and appearance, data augmentation reduces overfitting risks and enables the model to learn invariant features relevant to MS lesion detection across different imaging scenarios.

### Experimental Setup

The MRI datasets utilized in this research were sourced from reputable neuroimaging repositories such as the OASIS-MS and proprietary datasets from collaborating medical institutions specializing in MS research. The datasets consist of multi-sequence MRI scans, including T1-weighted, T2-weighted, and FLAIR sequences, all standardized to  $1 \times 1 \times 1$  mm resolution, acquired using 3 TMRI machines from various manufacturers such as Siemens, GE Healthcare, and Philips. Table 1 shows the multiple convolution layers.

#### Preprocessing Steps

- Image Normalization.** Intensity values across MRI sequences were standardized to mitigate inter-scan variability and ensure consistent input data for the neural network model.
- Brain Extraction.** Non-brain tissues were removed via skull stripping techniques to focus the analysis on relevant brain regions.
- Lesion Segmentation.** Automated and semi-automated segmentation algorithms (e.g., region growing, active

Table 1. Multiple convolutional layers

Layer Type	Details
Convolutional Layers	Feature extraction with varying filter sizes
Activation Functions	ReLU for introducing non-linearity
Pooling Layers	Max-pooling for downsampling feature maps
Fully Connected Layers	Dense layers for feature aggregation
Output Layer	Softmax activation for multi-class classification

contour models) were employed to delineate MS lesion areas from the brain images.

- Manual Quality Control.** Expert neuroimaging specialists validated and refined the lesion segmentation results to ensure accurate lesion boundaries and labeling.

**MSNet Architecture.** MSNet is designed as a custom CNN architecture tailored for MS lesion detection and classification from MRI images. The architecture comprises multiple convolutional layers for feature extraction, followed by fully connected layers for classification as in Table 1.

In our experimental setup, we utilized a variety of MRI imaging methods to capture different aspects of brain anatomy and pathology related to MS. The images included in our analysis spanned various sequences; each providing unique insights into the structural and functional changes associated with MS lesions. Here, we present an example of different MRI imaging methods, such as FLAIR, Magnetization Prepared Rapid Acquisition Gradient Echo (MPRAGE), Proton Density (PD), and Transverse Relaxation Time (T2). FLAIR imaging is sensitive to fluid accumulation, making it particularly useful for highlighting MS lesions, which often present with increased fluid content. FLAIR images suppress the signal from Cerebrospinal Fluid (CSF), enhancing the visibility of lesions against a dark background. MPRAGE sequences provide high-resolution anatomical images with excellent tissue contrast, allowing for detailed visualization of brain structures. While MPRAGE images may not specifically target MS lesions, they offer valuable anatomical context for lesion localization. PD-weighted images are sensitive to variations in proton density, offering good contrast between different types of brain tissues. In the context of MS, PD images can help delineate lesions based on their distinct proton density characteristics compared to surrounding normal tissue. T2-weighted images are highly sensitive to changes in tissue water content, making them well-suited for detecting MS lesions, which often exhibit increased water content due to inflammation and demyelination. T2 images typically show lesions as hyperintense (bright) areas against a darker background. Additionally, we provide a sample Gaussian-filtered version of a T2-weighted image which enhances image clarity and reduces noise, improving lesion visibility and segmentation accuracy. Finally, a mask or label with white lesion pixels is overlaid on the images, indicating the regions identified as MS lesions by expert annotation or automated segmentation algorithms.

Fig. 2 shows the MRI images with different imaging methods, each standardized to a resolution of  $256 \times 256$  pixels ( $1 \times 1$  mm per pixel). Fig. 2, *a* provides the high-resolution anatomical detail, with fat appearing bright and water appearing dark. It helps in identifying structural abnormalities in the brain. Fig. 2, *b* highlights areas with higher water content, making water appear bright. It is particularly effective for detecting edema and MS lesions due to their higher water content.

Fig. 2, *c* shows the FLAIR Image. This image suppresses the signal from CSF, making lesions near the CSF more visible. It is especially useful for identifying periventricular MS lesions. Fig. 2, *d* shows the PD-weighted image. This image offers good contrast between gray and white matter by highlighting differences in proton density, without emphasizing fluid content. It complements the information provided by T1 and T2 images. These MRI imaging methods, along with Gaussian filtering and lesion masks, collectively provide a comprehensive dataset for training and evaluating our proposed MSNet architecture for MS lesion detection and classification.

Fig. 3 depicts a segment of an MRI scan, showcasing three distinct lesions associated with MS. Each lesion presents as a hyperintense (bright) area against the surrounding brain tissue, indicating pathological changes characteristic of MS. These lesions are identifiable across multiple MRI sequences, including FLAIR, T2-weighted, and PD-weighted images, highlighting their diverse appearance, and spatial distribution within the brain.

Fig. 4, *a* shows the unprocessed image which provides a raw representation of the brain anatomy and tissue characteristics captured during the MRI acquisition process.

In Fig. 4, *b* the original MR image undergoes convolution with a specified kernel or filter. Convolution involves applying the filter to different regions of the input image to extract specific features or enhance certain spatial patterns. Fig. 4, *c* depicts the convolved image after undergoing maximum pooling, a down sampling operation commonly used in CNNs.

## Results and Discussion

The performance of the MSNet model in MS lesion detection and classification tasks was evaluated using rigorous quantitative metrics, showcasing its efficacy and reliability in clinical applications.

### Quantitative Performance Metrics.

**Accuracy Rate — 98.2 %.** The high accuracy rate reflects the model ability to correctly classify MS lesions from non-lesion areas with exceptional precision, indicating a robust classification framework.

**Sensitivity (True Positive Rate) — 95.6 %.** MSNet demonstrated high sensitivity in identifying true positive cases, accurately detecting the majority of MS lesions present in the MRI images.

**Specificity (True Negative Rate) — 99.1 %.** The model exhibited excellent specificity, effectively distinguishing non-lesion areas from MS lesions, thereby minimizing false positives in the classification process.

**Dice Coefficient — 0.91.** The Dice coefficient, measuring segmentation accuracy, revealed strong agreement between the predicted and ground truth lesion masks. This high value signifies accurate delineation and localization of MS lesions by MSNet.

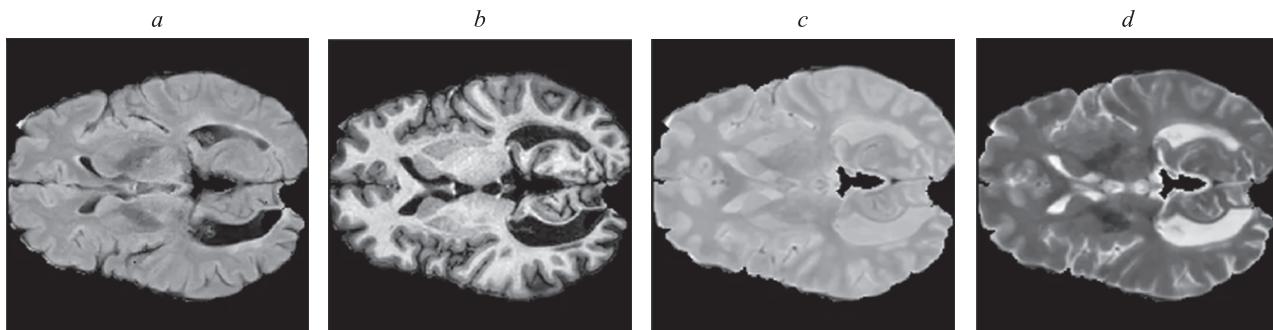


Fig. 2. MRI images with different imaging methods: T1-Weighted Image (*a*), T2-Weighted Image (*b*), FLAIR Image (*c*), PD-Weighted Image (*d*)

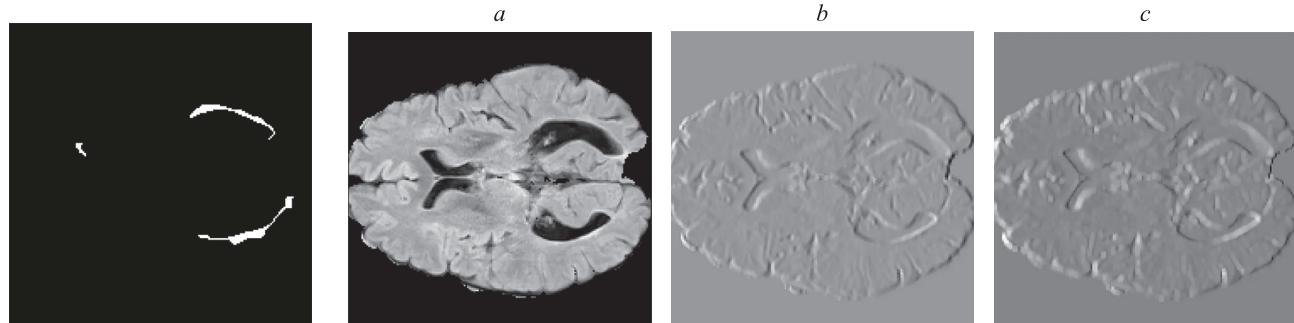


Fig. 3. Mask image

Fig. 4. MRI images after filtering methods: MR image (*a*), convolved image (*b*), max pooled image (*c*)

**Area Under the Curve (AUC) — 0.976.** MSNet achieved a high AUC score, indicating its superior discriminative power between MS lesion and non-lesion areas, further validating its effectiveness in lesion detection tasks.

A comparative analysis is conducted with existing methods in MS lesion detection using MRI images. MSNet outperforms traditional machine learning approaches and demonstrates superior accuracy, sensitivity, and specificity rates. The model ability to accurately classify MS lesions from other brain pathologies is a significant improvement over previous methods. Visualizations of MS

lesion detection outcomes are presented, highlighting the detection and classification of lesions in both Deep Gray Matter and Medial Temporal Lobe areas. Segmentation masks overlaid on MRI images showcase the model ability to delineate lesions accurately, aiding in clinical diagnosis and treatment planning. Table 2 shows the comparative analysis.

The comparative table presents an insightful analysis of the proposed MSNet model against three existing works in MS lesion detection and classification tasks using MRI images. MSNet, the model proposed in this study, showcases superior performance across multiple

Table 2. Comparative analysis

Method	Accuracy, %	Sensitivity, %	Specificity, %	Dice Coefficient	AUC
MSNet (Proposed)	98.2	95.6	99.1	0.91	0.976
Extreme Learning Machine [10]	92.5	88.2	94.7	0.85	0.918
Watershed-Clustering Algorithm [14]	89.3	85.6	91.7	0.81	0.899
Harris Hawks Optimization [15]	91.8	87.5	93.2	0.83	0.912

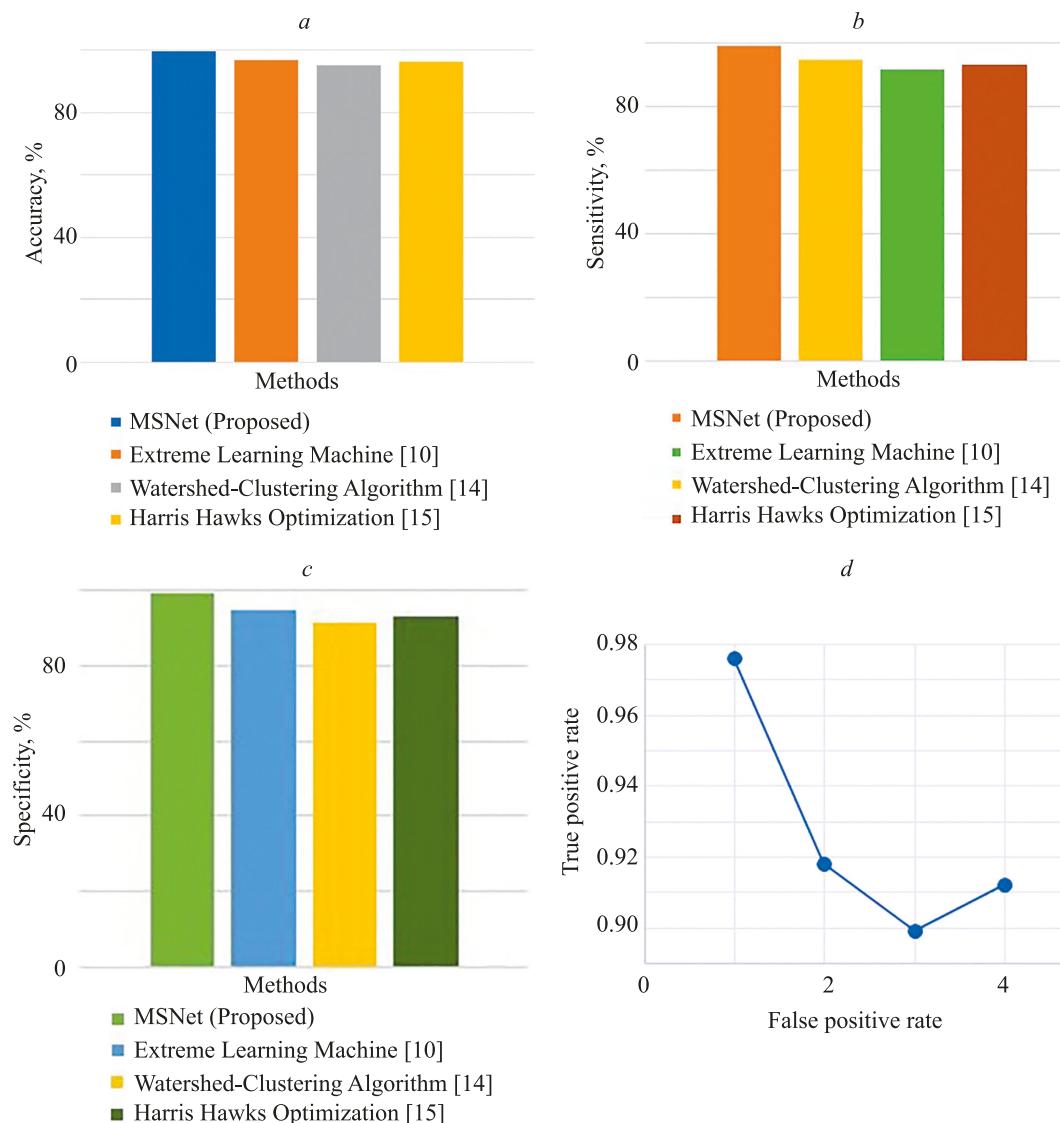


Fig. 5. Performance Comparison: Accuracy Comparison (a); Sensitivity Comparison (b); Specificity (c); AUC curve (d)

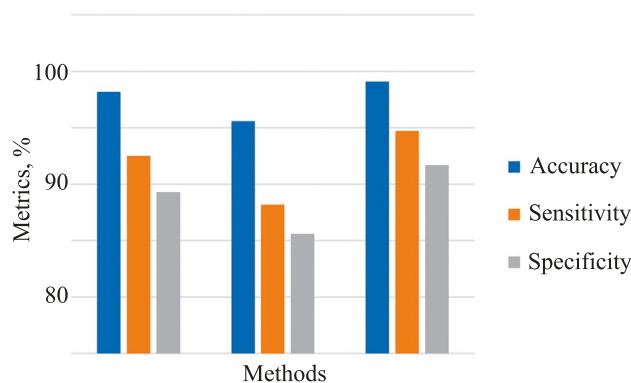


Fig. 6. Overall Comparative analysis

evaluation metrics compared to other methods. With an impressive accuracy rate of 98.2 %, MSNet significantly outperforms the Extreme Learning Machine, Rezaee et al. [10], Watershed-Clustering Algorithm [14], and Harris Hawks Optimization [15] models which reported accuracy rates of 92.5 %, 89.3 %, and 91.8 %, respectively. Moreover, MSNet exhibits higher sensitivity (95.6 %) and specificity (99.1 %) rates, indicating its ability to accurately detect MS lesions while minimizing false positives. The Dice coefficient of 0.91 and AUC value of 0.976 further validate the robustness and reliability of MSNet in segmenting and classifying MS lesions. These results highlight the significant advancements achieved by MSNet in automated MS lesion detection, emphasizing its potential for enhancing clinical diagnosis and patient care in MS management. The results are shown in Fig. 5, and 6.

Overall comparative analysis is shown in Fig. 6. The high accuracy rate of 98.2 % reflects the robustness and reliability of MSNet in automated MS lesion detection. The model sensitivity (95.6 %) and specificity (99.1 %) rates indicate its ability to correctly identify MS lesions while minimizing false positives. The Dice coefficient of 0.91 signifies strong agreement between predicted and ground truth lesion masks.

MSNet strengths lie in its deep learning architecture tailored for MS lesion analysis, effective utilization of multi-sequence MRI inputs, and robust performance across diverse lesion types and locations. However, limitations, such as computational complexity during training and the need for expert validation in lesion labeling, should be considered for practical deployment.

Accurate MS lesion classification using MSNet has profound implications for clinical practice. Early and precise detection of MS lesions facilitates timely intervention and treatment planning, improving patient outcomes and quality of life. The model automated analysis reduces diagnostic burden on clinicians and enhances diagnostic accuracy, especially in complex cases or early disease stages.

## Conclusion

In this study, we proposed MSNet, a customized Convolutional Neural Network (CNN) framework for the detection and classification of Multiple Sclerosis (MS) lesions in Magnetic Resonance Imaging (MRI) images. Our experimental results demonstrate the effectiveness of MSNet in accurately identifying MS lesions across various metrics. The comparative analysis with existing methods, such as the Extreme Learning Machine, Watershed-Clustering Algorithm, and Harris Hawks Optimization, highlights the superior performance of MSNet in terms of accuracy, sensitivity, specificity, and Dice Coefficient. The MSNet model achieved an impressive accuracy rate of 98.2 %, sensitivity of 95.6 %, and specificity of 99.1 %, showcasing its robustness in distinguishing MS lesions from other brain pathologies. The incorporation of advanced deep learning techniques, including multi-sequence MRI inputs and customized CNN architectures, enhances the model ability to capture intricate lesion patterns and improve diagnostic accuracy. Moreover, the utilization of data augmentation strategies during model training contributes to better generalization and reduced overfitting risks. These results signify the potential of deep learning-based approaches in revolutionizing MS diagnosis and patient care. Accurate and early detection of MS lesions using automated methods like MSNet can significantly aid clinicians in timely intervention and treatment planning, ultimately improving patient outcomes and quality of life. Future research should focus on integrating MSNet with additional imaging modalities, incorporating the latest advancements in transformer-based neural networks, optimizing performance on larger and more diverse datasets, and refining the model for real-time clinical applications to further enhance its utility in MS diagnosis.

## References

- López-Dorado A., Pérez J., Rodrigo M.J., Miguel-Jiménez J.M., Ortiz M., de Santiago L., López-Guillén E., Blanco R., Cavalliere C., Morla E.M.S., Boquete L., García-Martin E. Diagnosis of multiple sclerosis using multifocal ERG data feature fusion. *Information Fusion*, 2021, vol. 76, pp. 157–167. <https://doi.org/10.1016/j.inffus.2021.05.006>
- Mohseni E., Moghaddasi S.M. A hybrid approach for MS diagnosis through nonlinear EEG descriptors and metaheuristic optimized classification learning. *Computational Intelligence and Neuroscience*, 2022, vol. 2022, pp. 5430528. <https://doi.org/10.1155/2022/5430528>
- Ahmadi A., Davoudi S., Daliri M.R. Computer Aided Diagnosis System for multiple sclerosis disease based on phase to amplitude coupling in covert visual attention. *Computer Methods and Programs*

## Литература

- López-Dorado A., Pérez J., Rodrigo M.J., Miguel-Jiménez J.M., Ortiz M., de Santiago L., López-Guillén E., Blanco R., Cavalliere C., Morla E.M.S., Boquete L., García-Martin E. Diagnosis of multiple sclerosis using multifocal ERG data feature fusion // *Information Fusion*. 2021. V. 76. P. 157–167. <https://doi.org/10.1016/j.inffus.2021.05.006>
- Mohseni E., Moghaddasi S.M. A hybrid approach for MS diagnosis through nonlinear EEG descriptors and metaheuristic optimized classification learning // *Computational Intelligence and Neuroscience*. 2022. V. 2022. P. 5430528. <https://doi.org/10.1155/2022/5430528>
- Ahmadi A., Davoudi S., Daliri M.R. Computer Aided Diagnosis System for multiple sclerosis disease based on phase to amplitude coupling in covert visual attention // *Computer Methods and Programs*

- in Biomedicine*, 2019, vol. 169, pp. 9–18. <https://doi.org/10.1016/j.cmpb.2018.11.006>
4. Karaca B.K., Aksahin M.F., Öcal R. Detection of multiple sclerosis from photic stimulation EEG signals. *Biomedical Signal Processing and Control*, 2021, vol. 67, pp. 102571. <https://doi.org/10.1016/j.bspc.2021.102571>
  5. De Santiago L., Morla E.M.S., Ortiz M., López E., Usanos C.A., Alonso-Rodríguez M.C., Barea R., Cavalieri-Ballesta C., Fernández A., Boquete L. A computer-aided diagnosis of multiple sclerosis based on mfVEP recordings. *PLoS ONE*, 2019, vol. 14, no. 4, pp. e0214662. <https://doi.org/10.1371/journal.pone.0214662>
  6. Yperman J., Becker T., Valkenborg D., Popescu V., Hellings N., Van Wijmeersch B., Peeters L.M. Machine learning analysis of motor evoked potential time series to predict disability progression in multiple sclerosis. *BMC Neurology*, 2020, vol. 20, no. 1, pp. 105. <https://doi.org/10.1186/s12883-020-01672-w>
  7. Solana E., Martínez-Heras E., Casas-Roma J., Calvet L., Lopez-Soley E., Sepulveda M., Sola-Valls N., Montej C., Blanco Y., Pulido-Valdeolivas I., Andorra M., Saiz A., Prados F., Llufriu S. Modified connectivity of vulnerable brain nodes in multiple sclerosis, their impact on cognition and their discriminative value. *Scientific Reports*, 2019, vol. 9, pp. 20172. <https://doi.org/10.1038/s41598-019-56806-z>
  8. Kawahara J. *Spinal Cord Segmentation and Disability Prediction in Multiple Sclerosis Using Novel Optimization and Machine Learning Methods*: Ph.D. Dissertation. Vancouver Island University, Nanaimo, BC, Canada. 2013, 57 p.
  9. Zhang H., Alberts E., Pongratz V., Mühlau M., Zimmer C., Wiestler B., Eichinger P. Predicting conversion from clinically isolated syndrome to multiple sclerosis—An imaging-based machine learning approach. *NeuroImage Clinical*, 2019, vol. 21, pp. 101593. <https://doi.org/10.1016/j.nicl.2018.11.003>
  10. Rezaee A., Rezaee K., Haddadnia J., Gorji H.T. Supervised meta-heuristic extreme learning machine for multiple sclerosis detection based on multiple feature descriptors in MR images. *SN Applied Sciences*, 2020, vol. 2, no. 5, pp. 866. <https://doi.org/10.1007/s42452-020-2699-y>
  11. Ekşioğlu M., Özcan E.M., Çakıroğlu M., Öz C., Aralasmak A. Differentiation of multiple sclerosis lesions and low-grade brain tumors on MRS data: Machine learning approaches. *Neurological Sciences*, 2021, vol. 42, no. 8, pp. 3389–3395. <https://doi.org/10.1007/s10072-020-04950-0>
  12. Peng Y., Zheng Y., Tan Z., Liu J., Xiang Y., Liu H., Dai L., Xie Y., Wang J., Zeng C., Li Y. Prediction of unenhanced lesion evolution in multiple sclerosis using radiomics-based models: A machine learning approach. *Multiple Sclerosis and Related Disorders*, 2021, vol. 53, pp. 102989. <https://doi.org/10.1016/j.msard.2021.102989>
  13. Eshaghi A., Young A.L., Wijeratne P.A., Prados F., Arnold D.L., Narayanan S., Guttmann C.R.G., Barkhof F., Alexander D.C., Thompson A.J., Chard D., Ciccarelli O. Identifying multiple sclerosis subtypes using unsupervised machine learning and MRI data. *Nature Communications*, 2021, vol. 12, no. 1, pp. 2078. <https://doi.org/10.1038/s41467-021-22265-2>
  14. Bonanno L., Mammone N., De Salvo S., Bramanti A., Rifici C., Sessa E., Bramanti P., Marino S., Ciurleo R. Multiple Sclerosis lesions detection by a hybrid Watershed-Clustering algorithm. *Clinical Imaging*, 2021, vol. 72, pp. 162–167. <https://doi.org/10.1016/j.clinimag.2020.11.006>
  15. Iswisi A.F.A., Karan O., Rahebi J. Diagnosis of Multiple Sclerosis Disease in Brain Magnetic Resonance Imaging Based on the Harris Hawks Optimization Algorithm. *BioMed Research International*, 2021, pp. 3248834. <https://doi.org/10.1155/2021/3248834>
  16. Jain S., Rajpal N., Yadav J. Supervised and unsupervised machine learning techniques for multiple sclerosis identification: A performance comparative analysis. *Advances in Intelligent Systems and Computing*, 2022, vol. 1374, pp. 369–381. [https://doi.org/10.1007/978-981-16-3346-1\\_30](https://doi.org/10.1007/978-981-16-3346-1_30)
  17. Garcia-Martin E., Ortiz M., Boquete L., Sánchez-Morla E.M., Barea R., Cavalieri C., Vilades E., Orduna E., Rodrigo M.J. Early diagnosis of multiple sclerosis by OCT analysis using Cohen's d method and a neural network as classifier. *Computers in Biology and Medicine*, 2021, vol. 129, pp. 104165. <https://doi.org/10.1016/j.combiomed.2020.104165>
  18. Montolio A., Cegoñino J., Garcia-Martin E., Pérez del Palomar A. Comparison of machine learning methods using spectralis OCT for diagnosis and disability progression prognosis in multiple sclerosis. *Annals of Biomedical Engineering*, 2022, vol. 50, no. 5, pp. 507–528. <https://doi.org/10.1007/s10439-022-02930-3>
  19. in Biomedicine. 2019. V. 169. P. 9–18. <https://doi.org/10.1016/j.cmpb.2018.11.006>
  20. Karaca B.K., Aksahin M.F., Öcal R. Detection of multiple sclerosis from photic stimulation EEG signals // *Biomedical Signal Processing and Control*. 2021. V. 67. P. 102571. <https://doi.org/10.1016/j.bspc.2021.102571>
  21. De Santiago L., Morla E.M.S., Ortiz M., López E., Usanos C.A., Alonso-Rodríguez M.C., Barea R., Cavalieri-Ballesta C., Fernández A., Boquete L. A computer-aided diagnosis of multiple sclerosis based on mfVEP recordings // *PLoS ONE*. 2019. V. 14. N 4. P. e0214662. <https://doi.org/10.1371/journal.pone.0214662>
  22. Yperman J., Becker T., Valkenborg D., Popescu V., Hellings N., Van Wijmeersch B., Peeters L.M. Machine learning analysis of motor evoked potential time series to predict disability progression in multiple sclerosis // *BMC Neurology*. 2020. V. 20. N 1. P. 105. <https://doi.org/10.1186/s12883-020-01672-w>
  23. Solana E., Martínez-Heras E., Casas-Roma J., Calvet L., Lopez-Soley E., Sepulveda M., Sola-Valls N., Montej C., Blanco Y., Pulido-Valdeolivas I., Andorra M., Saiz A., Prados F., Llufriu S. Modified connectivity of vulnerable brain nodes in multiple sclerosis, their impact on cognition and their discriminative value // *Scientific Reports*. 2019. V. 9. P. 20172. <https://doi.org/10.1038/s41598-019-56806-z>
  24. Kawahara J. Spinal Cord Segmentation and Disability Prediction in Multiple Sclerosis Using Novel Optimization and Machine Learning Methods: Ph.D. Dissertation. Vancouver Island University, Nanaimo, BC, Canada. 2013, 57 p.
  25. Zhang H., Alberts E., Pongratz V., Mühlau M., Zimmer C., Wiestler B., Eichinger P. Predicting conversion from clinically isolated syndrome to multiple sclerosis—An imaging-based machine learning approach // *NeuroImage Clinical*. 2019. V. 21. P. 101593. <https://doi.org/10.1016/j.nicl.2018.11.003>
  26. Rezaee A., Rezaee K., Haddadnia J., Gorji H.T. Supervised meta-heuristic extreme learning machine for multiple sclerosis detection based on multiple feature descriptors in MR images // *SN Applied Sciences*. 2020. V. 2. N 5. P. 866. <https://doi.org/10.1007/s42452-020-2699-y>
  27. Ekşioğlu M., Özcan E.M., Çakıroğlu M., Öz C., Aralasmak A. Differentiation of multiple sclerosis lesions and low-grade brain tumors on MRS data: Machine learning approaches // *Neurological Sciences*. 2021. V. 42. N 8. P. 3389–3395. <https://doi.org/10.1007/s10072-020-04950-0>
  28. Peng Y., Zheng Y., Tan Z., Liu J., Xiang Y., Liu H., Dai L., Xie Y., Wang J., Zeng C., Li Y. Prediction of unenhanced lesion evolution in multiple sclerosis using radiomics-based models: A machine learning approach // *Multiple Sclerosis and Related Disorders*. 2021. V. 53. P. 102989. <https://doi.org/10.1016/j.msard.2021.102989>
  29. Eshaghi A., Young A.L., Wijeratne P.A., Prados F., Arnold D.L., Narayanan S., Guttmann C.R.G., Barkhof F., Alexander D.C., Thompson A.J., Chard D., Ciccarelli O. Identifying multiple sclerosis subtypes using unsupervised machine learning and MRI data // *Nature Communications*. 2021. V. 12. N 1. P. 2078. <https://doi.org/10.1038/s41467-021-22265-2>
  30. Bonanno L., Mammone N., De Salvo S., Bramanti A., Rifici C., Sessa E., Bramanti P., Marino S., Ciurleo R. Multiple Sclerosis lesions detection by a hybrid Watershed-Clustering algorithm // *Clinical Imaging*. 2021. V. 72. P. 162–167. <https://doi.org/10.1016/j.clinimag.2020.11.006>
  31. Iswisi A.F.A., Karan O., Rahebi J. Diagnosis of Multiple Sclerosis Disease in Brain Magnetic Resonance Imaging Based on the Harris Hawks Optimization Algorithm // *BioMed Research International*. 2021. P. 3248834. <https://doi.org/10.1155/2021/3248834>
  32. Jain S., Rajpal N., Yadav J. Supervised and unsupervised machine learning techniques for multiple sclerosis identification: A performance comparative analysis // *Advances in Intelligent Systems and Computing*. 2022. V. 1374. P. 369–381. [https://doi.org/10.1007/978-981-16-3346-1\\_30](https://doi.org/10.1007/978-981-16-3346-1_30)
  33. Garcia-Martin E., Ortiz M., Boquete L., Sánchez-Morla E.M., Barea R., Cavalieri C., Vilades E., Orduna E., Rodrigo M.J. Early diagnosis of multiple sclerosis by OCT analysis using Cohen's d method and a neural network as classifier // *Computers in Biology and Medicine*. 2021. V. 129. P. 104165. <https://doi.org/10.1016/j.combiomed.2020.104165>
  34. Montolio A., Cegoñino J., Garcia-Martin E., Pérez del Palomar A. Comparison of machine learning methods using spectralis OCT for diagnosis and disability progression prognosis in multiple sclerosis // *Annals of Biomedical Engineering*. 2022. V. 50. N 5. P. 507–528. <https://doi.org/10.1007/s10439-022-02930-3>

### Authors

**Mathavan Divya** — PhD, Researcher, SRM Institute of Science and Technology, Ramapuram Campus, Chennai, 600089, India, <https://orcid.org/0000-0002-9960-8061>, [divyam1@srmist.edu.in](mailto:divyam1@srmist.edu.in)  
**Jayeseelan Dhilipan** — PhD, Professor, Head, SRM Institute of Science and Technology, Ramapuram Campus, Chennai, 600089, India, [sc 57216892821](https://orcid.org/0000-0003-2122-5076), <https://orcid.org/0000-0003-2122-5076>, [hod.mca.rmp@srmist.edu.in](mailto:hod.mca.rmp@srmist.edu.in)  
**Appu Saravanan** — PhD, Professor, Easwari Engineering College, Ramapuram Campus, Chennai, 600089, India, <https://orcid.org/0000-0003-2093-900X>, [dean.academic@srmrmp.edu.in](mailto:dean.academic@srmrmp.edu.in)

### Авторы

**Дивья Матаван** — PhD, исследователь, Институт науки и технологий SRM, Кампус Рамапурам, Ченнаи, 600089, Индия, <https://orcid.org/0000-0002-9960-8061>, [divyam1@srmist.edu.in](mailto:divyam1@srmist.edu.in)  
**Дхилипан Джасилан** — PhD, профессор, руководитель, Институт науки и технологий SRM, Кампус Рамапурам, Ченнаи, 600089, Индия, [sc 57216892821](https://orcid.org/0000-0003-2122-5076), <https://orcid.org/0000-0003-2122-5076>, [hod.mca.rmp@srmist.edu.in](mailto:hod.mca.rmp@srmist.edu.in)  
**Сараванан Аппу** — PhD, профессор, Инженерный колледж Иасвари, Кампус Рамапурам, Ченнаи, 600089, Индия, <https://orcid.org/0000-0003-2093-900X>, [dean.academic@srmrmp.edu.in](mailto:dean.academic@srmrmp.edu.in)

Received 06.04.2024

Approved after reviewing 19.08.2024

Accepted 21.09.2024

Статья поступила в редакцию 06.04.2024

Одобрена после рецензирования 19.08.2024

Принята к печати 21.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-834-842  
УДК 004.4/.5

## Создание и анализ многомодального корпуса данных для автоматического распознавания агрессивного поведения людей

Михаил Юрьевич Уздяев<sup>1</sup>✉, Алексей Анатольевич Карпов<sup>2</sup>

<sup>1,2</sup> Санкт-Петербургский федеральный исследовательский центр Российской академии наук, Санкт-Петербург, 199178, Российская Федерация

<sup>1</sup> [uzdyaev.m@iias.spb.su](mailto:uzdyaev.m@iias.spb.su), <https://orcid.org/0000-0002-7032-0291>

<sup>2</sup> [karpov@iias.spb.su](mailto:karpov@iias.spb.su), <https://orcid.org/0000-0003-3424-652X>

### Аннотация

**Введение.** Развитие цифровых систем коммуникации сопряжено с растущим количеством проявлений деструктивного поведения людей и необходимостью оперативного на него реагирования. Ввиду слабой формализации предметной области агрессии, наиболее перспективными методами распознавания деструктивного поведения являются методы, основанные на подходах машинного обучения, которые для эффективной работы требуют репрезентативных выборок релевантных данных. При создании корпусов поведенческих данных необходимо решить следующие проблемы: соответствие разметки данных корпуса реальному поведению; представленности поведения в однотипных ситуациях и в корпусе натурального поведения. Целью работы является разработка методики создания выборки многомодальных данных поведенческой агрессии человека, содержательно отражающей агрессию как явление и обеспечивающей релевантность данных. **Метод.** В работе описывается разработанная методика создания выборок многомодальных данных, содержащих спонтанное агрессивное поведение. В ходе содержательного анализа предметной области агрессивного поведения человека выделяются значимые атрибуты агрессии такие как явления (наличие субъекта и объекта агрессии, деструктивный характер агрессивного действия) и единицы анализа поведения (временные сегменты аудио и видео, на которых локализованы информанты); определяются типы регистрируемой агрессии (физическая и вербальная явные прямые); обосновываются критерии оценки агрессивного поведения каждого типа посредством введения перечня действий, однозначно определяющих каждый вид агрессии. Методика состоит из следующих этапов: сбор видео в открытом доступе в сети Интернет; выделение временных интервалов, на которых проявляется агрессия; локализация информантов на кадрах видео; транскрибирование реплик информантов; оценка актов физической и вербальной агрессии группой аннотаторов посредством разработанного алгоритма оценки поведения; вычисление согласованности оценок с помощью коэффициента Флейсса. **Основные результаты.** Для апробации методики создан и размещен группой аннотаторов аудиовизуальный корпус данных спонтанного агрессивного поведения русскоязычных информантов Audiovisual Aggressive Behavior in Online Streams (AVABOS). Корпус данных содержит видео- и аудиосегменты, на которых присутствует вербальная и физическая агрессия соответственно, проявляемые русскоязычными информантами в ходе онлайн-видеотрансляций. **Обсуждение.** Результаты согласованности разметки показали высокий уровень для физической агрессии ( $k = 0,74$ ) и средний уровень для вербальной ( $k = 0,48$ ), что подтверждает обоснованность разработанной методики. Корпус данных AVABOS может использоваться для решения задач автоматического распознавания агрессии человека. Помимо создания корпусов агрессивного поведения, методика также может использоваться для создания корпусов, содержащих другое поведение.

### Ключевые слова

методика создания многомодального корпуса, методика оценки поведения, агрессивное поведение, распознавание агрессии, создание выборки данных, оценка согласованности разметки, коэффициент Флейсса

### Благодарности

Исследование выполнено при финансовой поддержке Российского научного фонда (№ 22-11-00321, <https://www.rscf.ru/project/22-11-00321/>).

**Ссылка для цитирования:** Уздяев М.Ю., Карпов А.А. Создание и анализ многомодального корпуса данных для автоматического распознавания агрессивного поведения людей // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 834–842. doi: 10.17586/2226-1494-2024-24-5-834-842

© Уздяев М.Ю., Карпов А.А., 2024

## Creation and analysis of multimodal corpus for aggressive behavior recognition

Mikhail Yu. Uzdiaev<sup>1</sup>, Alexey A. Karpov<sup>2</sup>

<sup>1,2</sup> St. Petersburg Federal Research Center of the Russian Academy of Sciences, Saint Petersburg, 199178, Russian Federation

<sup>1</sup> uzdfaev.m@iias.spb.su, <https://orcid.org/0000-0002-7032-0291>

<sup>2</sup> karpov@iias.spb.su, <https://orcid.org/0000-0003-3424-652X>

### Abstract

The development of digital communication systems is associated with the increasing number of disruptive behavior incidents that require rapid response in order to prevent negative consequences. Due to weak formalization of human aggression, machine learning approaches are the most suitable for this area. Machine learning approaches require representative sets of relevant data for efficient aggression recognition. Datasets developing implies such problems as dataset labels relevance to the real behavior, the consistency of the situations, where behavior is manifested, and the naturalness of behavior. The purpose of this work is the development of an aggressive behavior datasets creation methodology that reflects the key aspects of aggression and provides relevant data. The work reveals the developed methodology for creation of multimodal datasets of natural aggression behavior. The analysis of human aggression subject area substantiates the key aspects of human aggression manifestations (the presence of subject and object of aggression, the destructiveness of the aggressive action), the behavior analysis units — the time intervals of audio and video with the localized informants, defines considering types of aggression (physical and verbal overt direct aggression), substantiates criteria for aggressive behavior assessment as a set of aggressive actions that define each aggression type. The methodology consists of the following stages: collecting video on the Internet, identifying time intervals where aggression is performed, localizing informants in video frames, transcribing informants' speech, collective labeling of physical and verbal aggression actions by a group of annotators (raters), assessing the reliability of annotations agreement using Fleiss' kappa coefficient. In order to evaluate the methodology a new audiovisual aggressive behavior in online streams corpus (AVABOS) was collected and labeled. The dataset contains audio and video segments that contain verbal and physical aggression correspondingly that manifested by Russian-speaking informants during online video streams. The results of interrater agreement reliability show substantial agreement for physical ( $\kappa = 0.74$ ) and moderate agreement for verbal aggression ( $\kappa = 0.48$ ) that substantiates the developed methodology. AVABOS dataset can be used in automatic aggression recognition tasks. The developed methodology can also be used for creating datasets with the other types of behavior.

### Keywords

methodology for creating multimodal dataset, methodology for behavior assessment, aggressive behavior, aggression recognition, dataset creation, collective labeling, interrater reliability assessment, Fleiss' kappa coefficient

### Acknowledgements

This work was supported financially by the Russian Science Foundation (project No. 22-11-00321, <https://www.rscf.ru/project/22-11-00321/>).

**For citation:** Uzdiaev M.Yu., Karpov A.A. Creation and analysis of multimodal corpus for aggressive behavior recognition. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 834–842 (in Russian). doi: 10.17586/2226-1494-2024-24-5-834-842

### Введение

Развитие социокиберфизических систем, которые обеспечивают взаимодействие значительного числа людей и различных компьютерных и роботизированных систем, сопровождается увеличением количества случаев проявления деструктивного поведения, к которому, в первую очередь, относятся проявления агрессии людьми. Такое поведение зачастую приводит к негативным последствиям, включая нанесение вреда здоровью и гибели жертв актов агрессии. Для оперативного реагирования на такие случаи необходимо внедрение эффективных систем автоматического распознавания деструктивного поведения, основанных на методах машинного обучения, которые требуют больших представительных корпусов данных, содержащих релевантные явления.

Необходимо обозначить основные проблемы, возникающие при создании корпусов многомодальных данных агрессивного поведения человека:

- 1) соответствие данных рассматриваемому типу поведения, которая выражается в выработке обоснованных критериев оценки поведения, куда вклю-

чены частные задачи определения типов агрессии, выделение существенных признаков для каждого типа, определения модальностей данных, в которых выражается агрессия;

- 2) однотипность ситуаций, в которых исполняется поведение, однотипность ситуаций может служить критерием для первичного отбора данных для их унификации;
- 3) естественность поведения, которая тесно связана с проблемой 1, так как естественность или спонтанность поведения напрямую влияет на соответствие данных реальному поведению;
- 4) выбор адекватных единиц анализа поведения, который связан с различием отдельных действий друг от друга и определением их временных границ, локализацией информантов, что особенно важно, когда участвуют несколько человек.

Целью исследования является разработка и апробация универсальной методики создания корпусов многомодальных данных, содержащих спонтанное агрессивное поведение русскоязычных информантов в ходе прямых видеотрансляций в сети Интернет. Поставлена задача преодоления проблем обоснования критериев

оценки поведения, недостаточного учета контекста ситуации и ненатуральности поведения.

Научная новизна предложенной методики состоит в выработке критериев оценки агрессивного поведения, которые представляют отдельные агрессивные действия и их существенные признаки. Выделены единицы анализа поведения: временные сегменты отдельных агрессивных действий с локализованными на них субъектами агрессии. В рамках апробации методики создан корпус многомодальных данных, содержащий спонтанное агрессивное поведение русскоязычных информантов.

### **Обзор методик создания корпусов поведенческих данных**

Созданию выборок агрессивного поведения людей посвящен ряд научных работ. В работах [1, 2] рассмотрено создание выборок, содержащих многомодальное агрессивное поведение на вокзале и в железнодорожных вагонах. Эти работы имеют схожие методики создания выборок данных: категории оценки выводятся на основе анализа научных работ; анализируются выделенные временные сегменты видео (без локализации информантов) или реплики информантов; записывается наигранное поведение; разметка производится группой аннотаторов с вычислением степени согласованности их мнений. В работе [1] приведено содержательное раскрытие категорий оценки, тогда как в [2] такая информация отсутствует. В [3] рассмотрены аспекты верbalной агрессии в парном взаимодействии между профессиональным актером и испытуемым, на которого направлена агрессия. Здесь методика создания воспроизводит методику из [2]. В других работах [4, 5] исследовано наигранное агрессивное поведение на видео (другие модальности не рассматриваются). В ходе создания корпусов данных [4, 5] разметка выполнялась одним аннотатором, критерии оценки поведения не формулировались, информанты, проявляющие агрессию, на кадрах видео не выделялись. Работы [6, 7] посвящены созданию выборок спонтанного агрессивного поведения, записанного на камеры видеонаблюдения. Разметка также выполнялась одним аннотатором, содержательно критерии оценки поведения не раскрывались, не выполнялось выделение информантов на видео.

В [8] раскрыты аспекты методики создания выборок, содержащих вербальную агрессию в тексте на русском, испанском и татарском языках (другие модальности не рассматриваются). Работы интересны тем, что в них содержательно описаны критерии оценки агрессии, взятые на основании анализа известных научных работ; разметка выполнялась одним аннотатором. Для смежных задач анализа эмоций и настроений в тексте при создании корпусов данных также выполнялась разметка одним аннотатором [9, 10].

В работах [11–14] рассмотрено создание выборок эмоционального поведения. В них имеются следующие сходства: категории оценки берутся из научных работ без их содержательного раскрытия, аннотация выполняется путем субъективной оценки группой аннотато-

ров степени выраженности определенной категории с вычислением степени согласованности оценок. Условия ситуации обычно подробно описываются, однако не воспроизводятся при записи. Информанты специально не выделяются, единицами анализа служат временные сегменты, соответствующие действиям и репликам информантов.

Обобщая особенности методик создания известных корпусов данных, можно выделить следующие общие свойства: в большинстве работ критерии оценки поведения содержательно не раскрываются; разметка выполняется посредством субъективной оценки поведения, зачастую без раскрытия критериев оценки; отдельные информанты на видео не локализуются, т. е. неправильно выбираются единицы анализа, что в дальнейшем затрудняет обработку поведения, если на видео несколько человек по-разному ведут себя; часто поведение записывается в лабораторных условиях, где не воспроизводятся реальные условия ситуаций, что затрудняет перенос результатов этих выборок на реальные условия. В работах, описывающих выборки поведения в естественных условиях, не уделяется должное внимание контролю условий записи и рассмотрению поведения в других модальностях, отличных от видео. Кроме того, недостаточно представлены русскоязычные корпуса, для которых авторы разрабатывали методики оценки поведения.

### **Методика создания корпусов многомодальных данных с агрессивным поведением человека**

Общая схема предлагаемой методики, а также детали, специфичные непосредственно для оценки агрессивного поведения человека, приведены на рис. 1. Рассмотрим этапы предложенной методики.

#### **Этап 1. Анализ предметной области**

**Выделение признаков ситуаций.** В рамках работы рассмотрено агрессивное поведение в ходе онлайн-видеотрансляций в сети Интернет, которые характеризуются следующими атрибутами: на видео присутствуют несколько участников различного пола и возраста, которые коммуницируют как между собой, так и со зрителями трансляции при помощи различных средств коммуникации. Трансляции ведутся в большинстве случаев из помещений (жилые или офисные помещения, специально оборудованные студии и т. д.) Сами участники обычно располагаются перед камерой, сидя за столом, стоя в полный рост или лежа. В ходе трансляции могут возникать ситуации, когда один или несколько участников начинают проявлять физическую или вербальную агрессию, вызванную различными причинами: состоянием опьянения, личной неприязнью, конфликтными ситуациями и др.

**Определение критериев оценки физической и вербальной агрессии.** Определение модальностей. В рамках анализа предметной области определяются критерии оценки агрессивного поведения, единицы анализа, а также модальности данных, в которых представлено поведение. В настоящей работе агрессия рассмотрена как деструктивное поведение, исполняемое субъектом агрессии (агрессором) по отношению

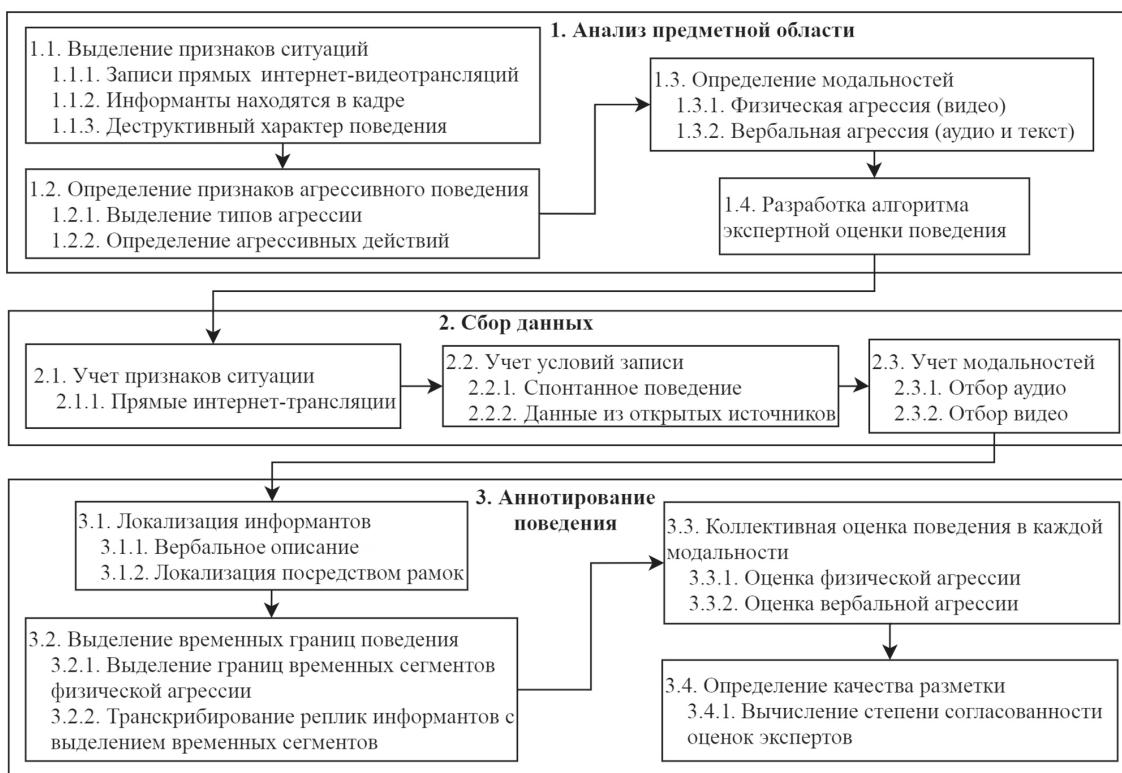


Рис. 1. Общая схема методики создания выборки данных поведенческой агрессии

Fig. 1. General scheme of aggressive behavior dataset creation methodology

к объекту агрессии (жертве), целью которого является нанесение ущерба жертве [15]. Выделим следующие характеристические признаки такого поведения, которые могут служить первичными критериями его оценки: обязательное присутствие субъекта агрессии; направленность поведения на внешний предмет (одушевленный или неодушевленный); поведение наносит ущерб объекту нападения. Помимо критериев оценки, данные признаки также служат для определения единиц анализа. Эти признаки определяют также единицы анализа при разметке выборки, которыми являются временные сегменты, на которых оценивается поведение агрессора, направленного на жертву. При этом обозначим необходимость обязательной локализации агрессора, без чего оценка поведения как агрессивного не может быть выполнена.

Оценка поведения внешним наблюдателем относится к методам не включенного внешнего наблюдения [16] за поведением, главной характеристикой которого является полное исключение влияния наблюдателя, что обеспечивает натуральность наблюданного поведения, а также объективный характер оценки. Признаками агрессивного поведения определим действия, однозначно относимые к тому или иному виду агрессии с учетом условий ситуации. Выделение перечня самих агрессивных действий основывается на содержательном анализе предметной области явной прямой физической и вербальной агрессии, а также статистического анализа результатов предварительного поискового наблюдения за агрессивным поведением русскоязычных пользователей в ходе прямых видеотрансляций [17]. В

методике в качестве критериев используются классы действий физической (захваты; кидание предметов; толчки; удары; укусы; обливание жидкостью; плевки; прочие акты физической агрессии) и вербальной (оскорблений; угрозы; грубые приказы; обвинения; поощрение насилия; прочие речевые акты) агрессии. Перечисленные классы агрессивных действий не исключают друг друга, т. е. информант может одновременно выполнять более одного действия. Подробное содержательное раскрытие критериев, а также примеры оценки поведения доступны в разработанной инструкции для разметки данных<sup>1</sup>.

В рамках настоящей работы рассмотрены видео-, аудио- и текстовая модальности ввиду того, что они наиболее полно отражают физическую и вербальную прямую явную агрессию (по классификации А. Басса [18]) в ходе прямых видеотрансляций.

**Разработка алгоритма экспертной оценки физической и вербальной агрессии.** На основании критериев агрессивных действий разработан алгоритм экспертной оценки, представляющий последовательность действий, которые должен выполнить аннотатор в ходе разметки при оценке неопределенных ситуаций.

— Если оценивается вербальная агрессия, выполняется приведение реплики информанта в утвердительную форму, если оно имеет вопросительную, сокращенную форму, форму косвенной речи или

<sup>1</sup> [Электронный ресурс]. Режим доступа: [https://github.com/cafe1930/AVABOS/blob/main/labelling\\_instruction.pdf](https://github.com/cafe1930/AVABOS/blob/main/labelling_instruction.pdf) (дата обращения: 08.08.2024).

- страдательного залога. Приведение высказывания к утвердительной форме снижает неопределенность при оценке реплики.
- Оценка ответного поведения жертвы. Демонстрация негативных эмоций и ответная агрессия свидетельствуют об ущербе жертве и об агрессивности действия агрессора.
  - Проверка наличия актов агрессии информанта до или после оцениваемого сегмента, что свидетельствует в пользу агрессивности оцениваемого интервала.
  - Оценка сопутствующего поведения агрессора. Демонстрация негативных эмоций агрессором, невербальное речевое поведение (высокий громкий голос), высокая двигательная активность свидетельствуют в пользу наличия агрессии.

Алгоритм служит для разрешения ситуаций, когда проявления агрессии носят неочевидный характер или слабо выражены путем раскрытия контекста оцениваемого действия.

**Этап 2. Сбор данных.** В многомодальный корпус данных поведенческой агрессии помещались видео с открытым доступом на видеохостинге YouTube, которые дополнительно фильтровались согласно критериям, описанным на этапе 1, «Выделение признаков ситуаций», чтобы все видео удовлетворяли условию однородности содержания. Открытый доступ видеоматериала означает публичную демонстрацию поведения, что не требует получения персонального согласия информантов на анализ публично демонстрируемого поведения.

**Разметка. Выделение временных интервалов физической и вербальной агрессии.** В рамках разметки актов физической агрессии первоочередной задачей является их временная локализация на видео. Выделены явно различимые границы начала и окончания как отдельных действий, так и последовательности однородных действий, если внутри этой последовательности невозможно отделить одно действие от другого. Дополнительно выделялись сегменты, где отсутствуют действия физической агрессии. В случае вербальной агрессии выполнялась полуавтоматическая диаризация и транскрибирование реплик с использованием моделей глубокого обучения Whisper [19, 20] с дальнейшей коррекцией вручную границ и текста реплик. Выделение временных сегментов физической агрессии

и транскрибирование реплик выполнялось посредством программного обеспечения (ПО) ELAN [21].

#### Локализация информантов на кадрах видео.

Выполнена локализация каждого информанта, участнико-вого в актах агрессии при помощи:

- структурированного верbalного описания отличительных особенностей их внешности: пол, прическа, одежда, обувь и т. д.;
- локализации описанных информантов прямоугольными рамками с последующим полуавтоматическим трекингом посредством ПО Video-Label-Tracker<sup>1</sup> (рис. 2).

**Этап 3. Процесс аннотирования данных.** Аннотирование выполнялось с использованием ПО ELAN (рис. 3) группой из пяти аннотаторов (двух мужского и трех женского пола). Возрастом от 20 до 32 лет (средний возраст — 26,4 лет, стандартное отклонение — 4,6 года), три аннотатора имеют высшее техническое образование, один — степень кандидата технических наук и один является студентом. Каждый из аннотаторов должен был определить наличие либо отсутствие агрессии в речевых действиях и двигательной активности каждого локализованного информанта на всех выделенных для него временных сегментах. Процесс аннотирования выполнен на основании критериев оценки действий и алгоритма экспертной оценки физической и вербальной агрессии. При этом на каждом оцениваемом сегменте может содержаться более одного класса агрессивных действий. В ходе разметки аннотаторы должны выделить все возможные классы физической и вербальной агрессии, проявляемой информантом на оцениваемом сегменте.

**Вычисление степени согласованности оценок аннотаторов.** Для оценки согласованности разметки выбран коэффициент ( $\kappa$ ) Флейссса [22]:

$$\kappa = \frac{P_a - P_e}{1 - P_e}, \quad (1)$$

где  $P_a$  — доля согласованных оценок, выполненных аннотаторами;  $P_e$  — доля ожидаемых случайных оценок. Выбор оценки обоснован тем, что она оценивает

<sup>1</sup> [Электронный ресурс]. Режим доступа: Video-Label-Tracker. <https://github.com/cafe1930/Video-Label-Tracker> (дата обращения: 08.08.2024).

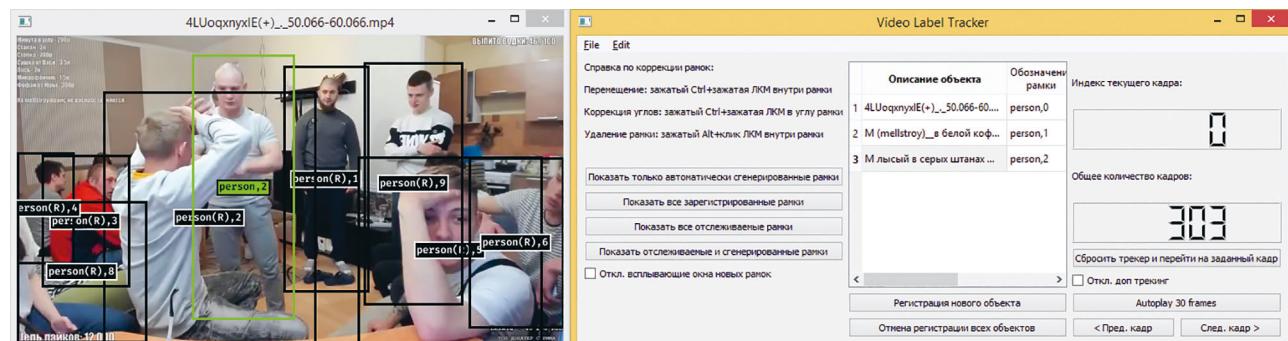


Рис. 2. Пример выполнения локализации информантов в программном обеспечении Video-Label-Tracker

Fig. 2. An example of informants localization using Video-Label-Tracker program

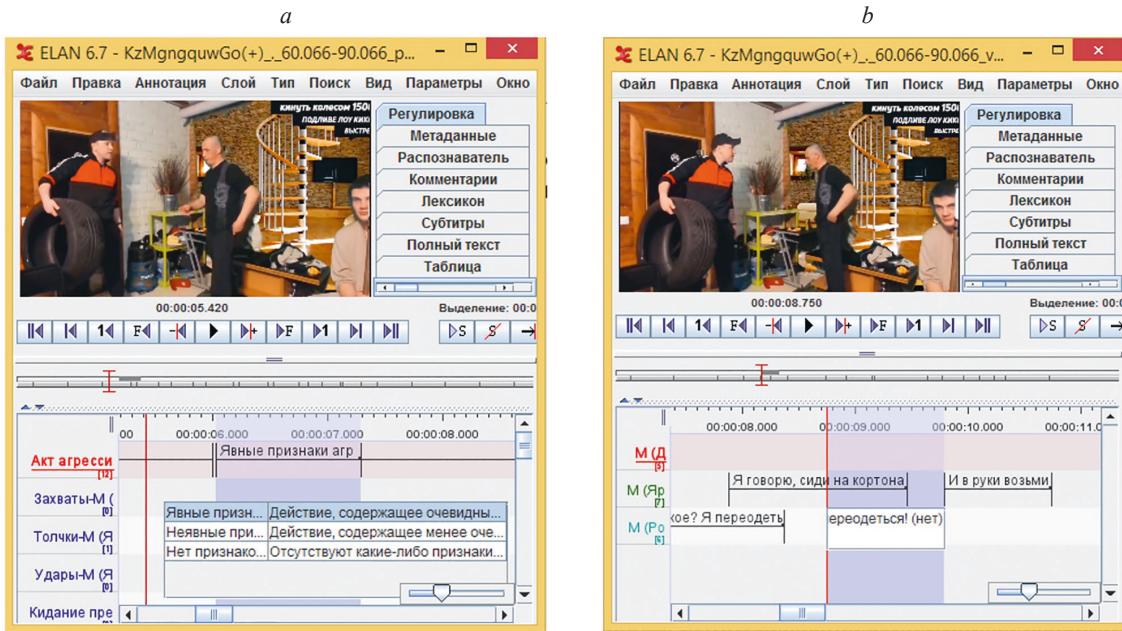


Рис. 3. Разметка физической (а) и вербальной (б) агрессии в программном обеспечении ELAN

Fig. 3. Labeling of physical (a) and verbal (b) aggression using ELAN annotation tool

согласованность нескольких аннотаторов, которые разметили все экземпляры данных в корпусе.

Ввиду того, что каждый оцениваемый временной сегмент или реплика в случае оценивания физической или верbalной агрессии может содержать более одного класса действий, вычислялась согласованность разметки для физической и вербальной агрессии в целом; сочетаний классов агрессивных действий, присваиваемых разными аннотаторами одним и тем же сегментам; отдельных классов агрессивных действий физической и вербальной агрессии.

### Результаты разметки корпуса данных

Предложенная методика была апробирована на практике, в результате чего создан аудиовизуальный корпус данных поведенческой агрессии в ходе онлайн-трансляций Audiovisual Aggressive Behavior in

Online Streams (AVABOS) [23]. Технические характеристики корпуса, приведены в табл. 1.

В связи с тем, что выполнялась коллективная разметка, класс агрессивного действия определялся путем мажоритарного голосования: присваивался класс агрессивного действия на основании совпадений оценок минимум трех аннотаторов из пяти. Статистика по количеству и длительности отдельных действий для каждого подвида вербальной и физической агрессии приведена в табл. 2. Поскольку на каждом оцениваемом сегменте данных может быть более одного типа агрессивных действий, в табл. 2 также приводится время и количество сегментов, где присутствует колонка «Наличие» и отсутствует колонка «Отсутствие» физической и вербальной агрессии.

Результаты оценок согласованности посредством коэффициента Флейсса (1) при совместной разметке физической и вербальной агрессии пятью аннотатора-

Таблица 1. Технические характеристики корпуса данных AVABOS

Table 1. Technical statistics of AVABOS

Параметр	Значение
Общая длительность данных, с	9490
Количество информантов	231 (167 мужчин, 64 женщины)
Количество видеофайлов	222
Общий объем данных, ГБ	1,6
Формат видео	mp4
Разрешение видео, пикселов	от 480 × 270 до 1280 × 720
Частота видеокадров, кадров/с	от 20 до 30
Формат аудиофайлов	M4A
Квантование аудиосигнала, бит	16
Частота дискретизации аудиосигнала, Гц	44 100

Таблица 2. Статистика данных по длительности и количеству агрессивных действий

Table 2. Time and number of actions statistics

Физическая агрессия										
Класс	Наличие	Отсутствие	Захваты	Толчки	Удары	Кидание предметов	Укусы	Обливание жидкостью	Плевки	Прочие акты физической агрессии
Длительность, с	3626	18 678	2704	258	550	14	10	8	0	37
Количество	2492	9723	1761	179	471	18	9	4	0	21
Вербальная агрессия										
Класс	Наличие	Отсутствие	Оскорблений	Угрозы	Грубые приказы	Обвинения	Поощрение насилия	Прочие речевые акты		
Длительность, с	4807	2581	1132	512	1089	1520	317	223		
Количество	2699	1870	598	251	696	734	175	129		

Таблица 3. Значения степени согласованности оценок аннотаторов к для физической и вербальной агрессии

Table 3. Values of interrater reliability  $\kappa$  for physical and verbal aggression assessment

Для физической агрессии										
Общее	Сочетания	Отсутствие	Захваты	Кидание предметов	Толчки	Удары	Укусы	Обливание жидкостью	Плевки	Прочие акты физической агрессии
0,74	0,68	0,74	0,72	0,53	0,41	0,67	0,87	0,54	0,25	0,09
Для вербальной агрессии										
Общее	Сочетания	Отсутствие	Оскорблений	Угрозы	Грубые приказы	Обвинения	Поощрение насилия	Прочие речевые акты		
0,48	0,48	0,48	0,64	0,69	0,63	0,58	0,50	0,13		

ми приведены в табл. 3. Колонка «Общее» содержит оценки согласованности при разметке наличия или отсутствия агрессии по всему корпусу данных, колонка «Сочетания» содержит оценки согласованности совпадения присваиваемых аннотаторами различных подвидов физической и вербальной агрессии для одних и тех же интервалов, колонка «Отсутствие» содержит оценки согласованности при разметке не агрессивных действий.

### Обсуждение

В результате анализа согласованности совместной разметки физической агрессии были получены значения оценок степени согласованности в целом ( $\kappa = 0,74$ ). Такое значение можно интерпретировать как высокий уровень согласованности оценок (диапазон  $0,61 \leq \kappa \leq 0,80$  согласно [24, 25]). Также высокий уровень согласованности был достигнут при оценке совпадения сочетаний классов агрессивных действий (0,68), отсутствия агрессии (0,74), отдельных классов «удары» (0,67) и «захваты» (0,72). Совместная разметка класса «толчки» (0,41) показала средний уровень согласованности оценок (диапазон  $0,41 \leq \kappa \leq 0,60$  согласно [24, 25]). Таким образом, для классов действий, представленных в корпусе данных наибольшим коли-

чеством (табл. 3), был достигнут высокий или средний уровень согласованности; для мало представленных классов получены высокий уровень согласованности («укусы»), средний («обливание жидкостью») и низкий («плевки», при том, что в корпусе отсутствуют сегменты, размеченные этим классом хотя бы тремя аннотаторами, а также «прочие действия») уровни.

Согласованность разметки вербальной агрессии показала более низкие результаты по сравнению с физической агрессией. Так, общая оценка согласованности при разметке вербальной агрессии (0,48) интерпретируется как средний уровень. Также средний уровень согласованности достигнут при разметке реплик, содержащих вербальную агрессию (0,48), совпадение сочетаний оценок классов агрессивных действий (0,48), классов «поощрение насилия» и «обвинения». При этом классы «оскорблений», «угрозы» и «грубые приказы» достигли высокого уровня согласованности. Отметим, что классы вербальной агрессии представлены в корпусе данных более равномерно, чем классы физической агрессии (табл. 2).

Лучшая, по сравнению с вербальной агрессией, согласованность разметки физической агрессии может быть обусловлена наличием у вербальной агрессии форм, отличных от утвердительной, наличию в корпусе реплик, содержащих нецензурные междометия, а также

различий в интерпретации реплик аннотаторами. Также следует отметить, что в данной работе выполнена оценка спонтанного поведения информантов, что также могло снизить согласованность. В других известных работах, где выполнялась совместная разметка агрессии [1, 2] оценивалось наигранное поведение. В работах, посвященных смежной теме создания корпусов эмоционального поведения [11, 14], были достигнуты схожие показатели согласованности с теми, которые получены в настоящей работе. Необходимо подчеркнуть, что разметка выполнялась специалистами с техническим образованием, которые размечали исходя из выведенных критериев оценки агрессии и алгоритму оценки. Исходя из этого, достигнутые результаты согласованности свидетельствуют о целесообразности применения в разметке выработанных критериев оценки агрессии, выделения единиц анализа, использования разработанного алгоритма оценки.

### Заключение

В работе представлена новая методика создания корпусов многомодальных данных для анализа спонтанного агрессивного поведения, отличающаяся содер- жательным раскрытием критериев оценки физической и вербальной агрессии, алгоритмом экспертной оцен-

ки, позволяющим размечать неочевидные примеры агрессии, выполнением совместной разметки группой аннотаторов спонтанного поведения.

Предложенная методика апробирована на практике, в результате чего создан аудиовизуальный корпус данных поведенческой агрессии AVABOS, содержащий спонтанное агрессивное поведение русскоязычных информантов в ходе прямых видеотрансляций в сети Интернет. Совместная разметка показала высокий уровень согласованности оценок аннотаторов при разметке физической агрессии и средний уровень при разметке вербальной агрессии. При этом при разметке отдельных классов как физической, так и вербальной агрессии также был достигнут высокий уровень согласованности оценок аннотаторов. Результаты оценок степени согласованности подтвердили целесообразность разработки настоящей методики.

Подход может быть использован для создания выборок как агрессивного, так и иного поведения с учетом коррекции на специфику другого типа поведения. Размеченный корпус AVABOS в дальнейшем планируется применять для создания и обучения нейросетевых моделей, предназначенных для одно- и многомодального моделирования и автоматического распознавания случаев агрессивного поведения людей.

### Литература

1. Lefter I., Rothkrantz L.J.M., Burghouts G.J. A comparative study on automatic audio–visual fusion for aggression detection using meta-information // *Pattern Recognition Letters*. 2013. V. 34. N 15. P. 1953–1963. <https://doi.org/10.1016/j.patrec.2013.01.002>
2. Lefter I., Burghouts G.J., Rothkrantz L.J.M. An audio-visual dataset of human–human interactions in stressful situations // *Journal on Multimodal User Interfaces*. 2014. V. 8. N 1. P. 29–41. <https://doi.org/10.1007/s12193-014-0150-7>
3. Lefter I., Jonker C.M., Tuent S.K., Veling W., Bogaerts S. NAA: A multimodal database of negative affect and aggression // Proc. of the Seventh International Conference on Affective Computing and Intelligent Interaction (ACII). 2017. P. 21–27. <https://doi.org/10.1109/ACII.2017.8273574>
4. Sernani P., Falcionelli N., Tomassini S., Contardo P., Dragoni A.F. Deep learning for automatic violence detection: Tests on the AIRTLab dataset // *IEEE Access*. 2021. V. 9. P. 160580–160595. <https://doi.org/10.1109/ACCESS.2021.3131315>
5. Ciampi L., Foszner P., Messina N., Staniszewski M., Gennaro C., Falchi F., Serao G., Cogiel M., Golba D., Szczęsna A., Amato G. Bus violence: An open benchmark for video violence detection on public transport // *Sensors*. 2022. V. 22. N 21. P. 8345. <https://doi.org/10.3390/s22218345>
6. Perez M., Kot A.C., Rocha A. Detection of real-world fights in surveillance videos // Proc. of the ICASSP 2019–2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2019. P. 2662–2666. <https://doi.org/10.1109/ICASSP2019.8683676>
7. Cheng M., Cai K., Li M. RWF-2000: An open large scale video database for violence detection // Proc. of the 25<sup>th</sup> International Conference on Pattern Recognition (ICPR). 2021. P. 4183–4190. <https://doi.org/10.1109/ICPR48806.2021.9412502>
8. Potapova R., Komalova L. On principles of annotated databases of the semantic field “aggression”//Lecture Notes in Computer Science. 2014. V. 8773. P. 322–328. [https://doi.org/10.1007/978-3-319-11581-8\\_40](https://doi.org/10.1007/978-3-319-11581-8_40)
9. Апанасович К.С., Махныткина О.В., Кабаров В.Й., Далевская О.П. RuPersonaChat: корпус диалогов для персонификации разговорных агентов // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24. № 2. С. 214–221. <https://doi.org/10.17586/2226-1494-2024-24-2-214-221>

### References

1. Lefter I., Rothkrantz L.J.M., Burghouts G.J. A comparative study on automatic audio–visual fusion for aggression detection using meta-information. *Pattern Recognition Letters*, 2013, vol. 34, no. 15, pp. 1953–1963. <https://doi.org/10.1016/j.patrec.2013.01.002>
2. Lefter I., Burghouts G.J., Rothkrantz L.J.M. An audio-visual dataset of human–human interactions in stressful situations. *Journal on Multimodal User Interfaces*, 2014, vol. 8, no. 1, pp. 29–41. <https://doi.org/10.1007/s12193-014-0150-7>
3. Lefter I., Jonker C.M., Tuent S.K., Veling W., Bogaerts S. NAA: A multimodal database of negative affect and aggression. *Proc. of the Seventh International Conference on Affective Computing and Intelligent Interaction (ACII)*, 2017, pp. 21–27. <https://doi.org/10.1109/ACII.2017.8273574>
4. Sernani P., Falcionelli N., Tomassini S., Contardo P., Dragoni A.F. Deep learning for automatic violence detection: Tests on the AIRTLab dataset. *IEEE Access*, 2021, vol. 9, pp. 160580–160595. <https://doi.org/10.1109/ACCESS.2021.3131315>
5. Ciampi L., Foszner P., Messina N., Staniszewski M., Gennaro C., Falchi F., Serao G., Cogiel M., Golba D., Szczęsna A., Amato G. Bus violence: An open benchmark for video violence detection on public transport. *Sensors*, 2022, vol. 22, no. 21, pp. 8345. <https://doi.org/10.3390/s22218345>
6. Perez M., Kot A.C., Rocha A. Detection of real-world fights in surveillance videos. *Proc. of the ICASSP 2019–2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 2662–2666. <https://doi.org/10.1109/ICASSP2019.8683676>
7. Cheng M., Cai K., Li M. RWF-2000: An open large scale video database for violence detection. *Proc. of the 25<sup>th</sup> International Conference on Pattern Recognition (ICPR)*, 2021, pp. 4183–4190. <https://doi.org/10.1109/ICPR48806.2021.9412502>
8. Potapova R., Komalova L. On principles of annotated databases of the semantic field “aggression”. *Lecture Notes in Computer Science*, 2014, vol. 8773, pp. 322–328. [https://doi.org/10.1007/978-3-319-11581-8\\_40](https://doi.org/10.1007/978-3-319-11581-8_40)
9. Апанасович К.С., Махныткина О.В., Кабаров В.Й., Далевская О.П. RuPersonaChat: корпус диалогов для персонификации разговорных агентов. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 2, pp. 214–221. (in Russian). <https://doi.org/10.17586/2226-1494-2024-24-2-214-221>

10. Hassoun Al-Jawad M.M., Alharbi H., Almukhtar A.F., Alnawas A.A. Constructing twitter corpus of Iraqi Arabic Dialect (CIAD) for sentiment analysis // Научно-технический вестник информационных технологий, механики и оптики. 2022. Т. 22. № 2. С. 308–316. <https://doi.org/10.17586/2226-1494-2022-2-2-308-316>
11. Busso C., Bulut M., Lee C., Kazemzadeh A., Mower E., Kim S., Chang J.N., Lee S., Narayanan S.S. IEMOCAP: Interactive emotional dyadic motion capture database // Language Resources and Evaluation. 2008. V. 42. N 4. P. 335–359. <https://doi.org/10.1007/s10579-008-9076-6>
12. Perepelkina O., Kazimirova E., Konstantinova M. RAMAS: Russian multimodal corpus of dyadic interaction for affective computing // Lecture Notes in Computer Science. 2018. V. 11096. P. 501–510. [https://doi.org/10.1007/978-3-319-99579-3\\_52](https://doi.org/10.1007/978-3-319-99579-3_52)
13. Ringeval F., Sonderegger A., Sauer J., Lalanne D. Introducing the RECOLA multimodal corpus of remote collaborative and affective interactions // Proc. of the 10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG). 2013. P. 1–8. <https://doi.org/10.1109/FG.2013.6553805>
14. Busso C., Parthasarathy S., Burmania A., AbdelWahab M., Sadoughi N., Provost E.M. MSP-IMPROV: An acted corpus of dyadic interactions to study emotion perception // IEEE Transactions on Affective Computing. 2017. V. 8. N 1. P. 67–80. <https://doi.org/10.1109/TFFC.2016.2515617>
15. Ениколов П.Н. Понятие агрессии в современной психологии // Прикладная психология. 2001. № 1. С. 60–72.
16. Groth-Marnat G., Wright A.J. Handbook of Psychological Assessment. John Wiley & Sons, 2016. 824 p.
17. Uzdiaev M., Vatamaniuk I. Investigation of manifestations of aggressive behavior by users of sociocyberphysical systems on video // Lecture Notes in Networks and Systems. 2021. V. 231. P. 593–604. [https://doi.org/10.1007/978-3-030-90321-3\\_49](https://doi.org/10.1007/978-3-030-90321-3_49)
18. Buss A.H. The Psychology of Aggression. John Wiley & Sons, 1961. 307 p. <https://doi.org/10.1037/11160-000>
19. Radford A., Kim J.W., Xu T., Brockman G., McLeavey C., Sutskever I. Robust speech recognition via large-scale weak supervision // International conference on machine learning (PMLR). 2023. V. 202. P. 28492–28518.
20. Plaquet A., Bredin H. Powerset multi-class cross entropy loss for neural speaker diarization // Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH. 2023. P. 3222–3226. <https://doi.org/10.21437/Interspeech.2023-205>
21. Lausberg H., Sloetjes H. Coding gestural behavior with the NEUROGES-ELAN system // Behavior Research Methods. 2009. V. 41. N 3. P. 841–849. <https://doi.org/10.3758/BRM.41.3.841>
22. Fleiss J.L. Measuring nominal scale agreement among many raters // Psychological Bulletin. 1971. V. 76. N 5. P. 378–382. <https://doi.org/10.1037/h0031619>
23. Уздейев М.Ю., Карпов А.А. Аудиовизуальный корпус данных поведенческой агрессии в ходе онлайн трансляций (Audiovisual Aggressive Behavior in Online Streams dataset – AVABOS). Свидетельство о государственной регистрации базы данных № 2022623239. 2022.
24. Landis J.R., Koch G.G. The measurement of observer agreement for categorical data // Biometrics. 1977. V. 33. N 1. P. 159–174. <https://doi.org/10.2307/2529310>
25. Fleiss J.L., Levin B., Paik M.C. Statistical Methods for Rates and Proportions. John Wiley & Sons, 2013. 800 p.
10. Hassoun Al-Jawad M.M., Alharbi H., Almukhtar A.F., Alnawas A.A. Constructing twitter corpus of Iraqi Arabic Dialect (CIAD) for sentiment analysis. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, vol. 22, no. 2, pp. 308–316. <https://doi.org/10.17586/2226-1494-2022-2-2-308-316>
11. Busso C., Bulut M., Lee C., Kazemzadeh A., Mower E., Kim S., Chang J.N., Lee S., Narayanan S.S. IEMOCAP: Interactive emotional dyadic motion capture database. *Language Resources and Evaluation*, 2008, vol. 42, no. 4, pp. 335–359. <https://doi.org/10.1007/s10579-008-9076-6>
12. Perepelkina O., Kazimirova E., Konstantinova M. RAMAS: Russian multimodal corpus of dyadic interaction for affective computing. *Lecture Notes in Computer Science*, 2018, vol. 11096, pp. 501–510. [https://doi.org/10.1007/978-3-319-99579-3\\_52](https://doi.org/10.1007/978-3-319-99579-3_52)
13. Ringeval F., Sonderegger A., Sauer J., Lalanne D. Introducing the RECOLA multimodal corpus of remote collaborative and affective interactions. *Proc. of the 10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG)*, 2013, pp. 1–8. <https://doi.org/10.1109/FG.2013.6553805>
14. Busso C., Parthasarathy S., Burmania A., AbdelWahab M., Sadoughi N., Provost E.M. MSP-IMPROV: An acted corpus of dyadic interactions to study emotion perception. *IEEE Transactions on Affective Computing*, 2017, vol. 8, no. 1, pp. 67–80. <https://doi.org/10.1109/TFFC.2016.2515617>
15. Enikolopov S.N. The concept of aggression in the contemporary psychology. *Prikladnaja psichologija*, 2001, no. 1, pp. 60–72. (in Russian)
16. Groth-Marnat G., Wright A.J. *Handbook of Psychological Assessment*. John Wiley & Sons, 2016. 824 p.
17. Uzdiaev M., Vatamaniuk I. Investigation of manifestations of aggressive behavior by users of sociocyberphysical systems on video. *Lecture Notes in Networks and Systems*, 2021, vol. 231, pp. 593–604. [https://doi.org/10.1007/978-3-030-90321-3\\_49](https://doi.org/10.1007/978-3-030-90321-3_49)
18. Buss A.H. *The Psychology of Aggression*. John Wiley & Sons, 1961, 307 p. <https://doi.org/10.1037/11160-000>
19. Radford A., Kim J.W., Xu T., Brockman G., McLeavey C., Sutskever I. Robust speech recognition via large-scale weak supervision. *International conference on machine learning (PMLR)*, 2023, vol. 202, pp. 28492–28518.
20. Plaquet A., Bredin H. Powerset multi-class cross entropy loss for neural speaker diarization. *Proc. of the Annual Conference of the International Speech Communication Association, INTERSPEECH*, 2023, pp. 3222–3226. <https://doi.org/10.21437/Interspeech.2023-205>
21. Lausberg H., Sloetjes H. Coding gestural behavior with the NEUROGES-ELAN system. *Behavior Research Methods*, 2009, vol. 41, no. 3, pp. 841–849. <https://doi.org/10.3758/BRM.41.3.841>
22. Fleiss J.L. Measuring nominal scale agreement among many raters. *Psychological Bulletin*, 1971, vol. 76, no. 5, pp. 378–382. <https://doi.org/10.1037/h0031619>
23. Uzdiaev M.Iu., Karlov A.A. Audiovisual Aggressive Behavior in Online Streams dataset – AVABOS. *Certificate of state registration of the database 2022623239*, 2022. (in Russian)
24. Landis J.R., Koch G.G. The measurement of observer agreement for categorical data. *Biometrics*, 1977, vol. 33, no. 1, pp. 159–174. <https://doi.org/10.2307/2529310>
25. Fleiss J.L., Levin B., Paik M.C. *Statistical Methods for Rates and Proportions*. John Wiley & Sons, 2013, 800 p.

## Авторы

**Уздейев Михаил Юрьевич** — младший научный сотрудник, Санкт-Петербургский федеральный исследовательский центр Российской академии наук, Санкт-Петербург, 199178, Российская Федерация,  57211179414, <https://orcid.org/0000-0002-7032-0291>, uzdyaev.m@iias.spb.su

**Карпов Алексей Анатольевич** — доктор технических наук, профессор, руководитель лаборатории, Санкт-Петербургский федеральный исследовательский центр Российской академии наук, Санкт-Петербург, 199178, Российская Федерация,  57219469958, <https://orcid.org/0000-0003-3424-652X>, karpov@iias.spb.su

Статья поступила в редакцию 12.08.2024

Одобрена после рецензирования 24.08.2024

Принята к печати 27.09.2024

## Authors

**Mikhail Yu. Uzdiaev** — Junior Researcher, St. Petersburg Federal Research Center of the Russian Academy of Sciences, Saint Petersburg, 199178, Russian Federation,  57211179414, <https://orcid.org/0000-0002-7032-0291>, uzdyaev.m@iias.spb.su

**Alexey A. Karpov** — D.Sc., Professor, Head of Laboratory, St. Petersburg Federal Research Center of the Russian Academy of Sciences, Saint Petersburg, 199178, Russian Federation,  57219469958, <https://orcid.org/0000-0003-3424-652X>, karpov@iias.spb.su

Received 12.08.2024

Approved after reviewing 24.08.2024

Accepted 27.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

doi: 10.17586/2226-1494-2024-24-5-843-848

## Single images 3D reconstruction by a binary classifier

Sallama Adhab Resen✉

Directorate General of Vocational Education, Baghdad, 1001, Iraq  
salamaresen@gmail.com✉, <https://orcid.org/0009-0007-5044-8857>

### Abstract

Intelligent systems demand interaction with a variety of complex environments. For example, a robot might need to interact with complicated geometric structures in an environment. Accurate geometric reasoning is required to define the objects navigating the scene properly. 3D reconstruction is a complex problem that requires massive amounts of images. The paper proposes producing intelligent systems for 3D reconstruction from single 2D images. Propose a learnable reconstruction context that uses features to realize the synthesis. Proposed methods produce encoding feature lable input to classification, pulling out that information to make better decisions. Binary Classifier Neural Network (BCNN) classifies whether a point is inside or outside the object. The reconstruction system models an object 3D structure and learns feature filter parameters. The geometry and the corresponding features are implicitly updated based on the loss function. The training doesn't require compressed supervision to visualize the task of reconstructed shapes and texture transfer. A point-set network flow results in BCNN having a comparable low memory footprint and is not restricted to specific classes for which templates are available. Accuracy measurements show that the model can extend the occupancy encoder by the generative model, which doesn't request an image condition but can be trained unconditionally. The time required to train the model will have more neurons and weight parameters overfitting.

### Keywords

intelligent systems, 3D reconstruction, features filter, convolution neural networks, Binary Classifier Neural Network (BCNN)

**For citation:** Resen S.A. Single images 3D reconstruction by a binary classifier. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 843–848. doi: 10.17586/2226-1494-2024-24-5-843-848

УДК 004.855

## Трехмерная реконструкция отдельных изображений с помощью бинарного классификатора

Саллама Адхаб Ресен✉

Главное управление профессионального образования, Багдад, 1001, Ирак  
salamaresen@gmail.com✉, <https://orcid.org/0009-0007-5044-8857>

### Аннотация

Интеллектуальные системы требуют взаимодействия с различными сложными окружающими средами. Например, роботу может потребоваться взаимодействовать в обстановке со сложными геометрическими структурами. Для правильного определения объектов, перемещающихся в пространстве, требуется точное геометрическое обоснование. 3D-реконструкция — сложная задача, требующая большого количества изображений. В работе предлагается создание интеллектуальных систем для 3D-реконструкции из отдельных 2D-изображений. Разработан обучаемый контекст реконструкции, который для реализации синтеза использует определенные признаки. Используемые методы осуществляют кодирование признаков метки входных данных для классификации, извлекая эту информацию для принятия более обоснованных решений. Бинарная сверточная нейронная сеть (Binary Classifier Neural Network, BCNN) классифицирует, находится ли точка внутри или снаружи объекта. Система реконструкции моделирует 3D-структуру объекта и изучает параметры фильтра признаков. Геометрия и соответствующие признаки обновляются на основе функции потерь. Обучение модели не требует сжатого наблюдения для визуализации задачи реконструированных форм и переноса текстуры. Поток сети с множеством точек приводит к тому, что BCNN занимает сравнительно малый объем памяти

© Resen S.A., 2024

и не ограничивается определенными классами, для которых доступны шаблоны. Исследование точности метрики показали, что модель может расширить кодировщик занятости с помощью генеративной модели, которая не запрашивает условие получения изображения и может быть обучена безусловно. Таким образом, за время, необходимое для обучения модели, создается большее количество нейронов и весовых переобученных параметров.

#### Ключевые слова

интеллектуальные системы, 3D-реконструкция, фильтр признаков, сверточные нейронные сети, двоичный классификатор нейронных сетей

**Ссылка для цитирования:** Ресен С.А. Трехмерная реконструкция отдельных изображений с помощью бинарного классификатора // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 843–848 (на англ. яз.). doi: 10.17586/2226-1494-2024-24-5-843-848

## Introduction

3D reconstruction is a challenging problem and has been discussed by many researchers and articles. A traditional 3D reconstruction pipeline takes input images. First, the camera poses for each image are computed using structure from motion or bundle adjustment, and then acute correspondences are computed across [1]. Many techniques represent output predicted by a deep neural network. 3D reconstruction for further optimization uses point representation, mesh refinement, or volumetric techniques. Geometric 3D representation illustrated in Fig. 1.

Voxel representations have been proposed for the reconstruction task as they are easy to process with neural networks. With voxel representation limitations, memory grows cubically in three dimensions. Outputs process at limited spatial resolution; the chosen coordinate system defines the voxels [2]. Voxel representations discretize the 3D space into regular grid cells, 2D and 3D. Mesh output representations for 3D reconstruction use deep neural networks. Meshes discretize space into vertices and faces but are still limited in the number of vertices. Meshes are patch-based approaches to self-intersections and non-watertight meshes. Mesh predictions by the neural network need help for output representation, where mesh needs a specific template to deform a mesh model instead of an explicit output representation. Point sets are another representation recently considered as output for neural networks. Point sets discretize the object's surface into 3D points to model the connectivity. Existing approaches could be more extensive in several points that can be processed. Local shape information is hard to encode; thus, point set generating networks involve global shape encoding. The

images have local and global information, but the essential local features are accurate. To examine further, add more details to the regional features. The idea of using the local and global features was investigated. The paper proposes an implicit output representation that does not require any discretization. It can parallel model arbitrary topology and arbitrary resolution on the Graphics Processing Units (GPU) and input as many points as fit into GPU memory. The method is not restricted to specific categories for available templates with comparable low memory; instead of having a deeper, fully connected network, proposed 3D convolutions are similar to convolutions on the 2D image space. The 2D convolutional network operates on the image domain. The 3D points query the image depending on the projection of the 3D point that falls into that image. Reconstructions were obtained for both geometry and feature representation. Models produce accurate reconstructions for huge spaces.

## Literature review

Remarkable progress has been made in 3D reconstruction, mainly credited to the rise of neural implicit modeling and advancements in differentiable rendering. Learning systems can learn dense, high-fidelity 3D from multi-view camera images. 3D reconstruction from a single image is challenging because it involves exploitation, visualization, and extracting information from images. The classical explicit representations differentiable rendering algorithms allow us to learn representations from 2D supervision only from RGB images [3]. Define a differentiable rendering algorithm architecture that combines geometry and appearance prediction [4]. The image encoder takes a 2D image and produces a global latent code for that image [5]. In [6], the forward and backward paths of the network are defined. The forward path corresponds to the rendering path [7]. The model can handle geometric details for entire scenes for single objects. The model leads to fewer occlusion artifacts than previous novel view synthesis baselines [8] which presented representations from 2D images, encode the input 3D shape using a point encoding into a global shape encoding and render the 3D shape into a depth map. 3D surface un-projection through the camera matrix was made for every pixel corresponding to the depth map [9]. Network architecture for predicting occupants has an encoder [10, 11]. The encoder depends on the condition of either a 2D image or a 3D point and on rough voxelization [12]. The encoder produces a set of conditioned layers.

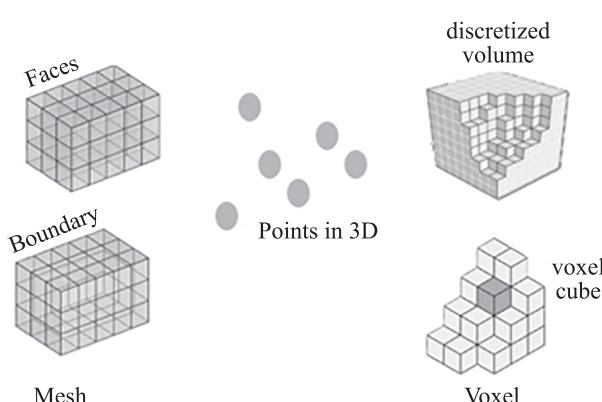


Fig. 1. Geometric 3D representation

These layers are conditioned on encoding and finding the 3D point location [13]. The shape encodes and predicts an RGB color value. Build generative versions of the model using adversarial loss encoder images. Single image texture reconstruction has the 2D input image and a 2D novel view synthesis baseline results. Synthesis baseline is hard in 2D to 3D translation. Building a model has investigated the representation power of the model reconstruction loss gain encoder [14, 15].

The predicted Neural Network (NN) model takes a point and passes it to a given image condition where the dots are the centers of the voxels [16]. 3D point queries the features using the neighbor interpolation technique. Integrate multiple views and get more precise results on the back of the model [17]. The work [18] combined the idea of implicit representations with primitive-based shape models. From [19] they proposed the universal differentiable renderer for NN representations. The work is considered the normal light location, and the 3D point matches the texture fields for the color value. Pixel- and feature-based reconstructions are performed in low and high-frequency domains. The fused view produced high-quality sentences. The paper found an analytic solution in comparison to a connected network. Instead of representing the 3D shape explicitly, consider the object implicitly as the decision boundary of a Binary Classifier Neural Network (BCNN) classifier. First, the NN geometry must be extracted in a post-processing step which consumes time. The extension to 3D is complex due to dimensionality. The 3D network operates on a fully connected network that has interpolated the features from the 2D image. 3D convolutions have to generate a 3D feature volume. The feature gets as input and predicts 3D object location based on authentic images.

### Single image 3D reconstruction

The framework covers two main parts: the learned feature module and 3D pixel reconstruction. The points set the generation network and detect occupancy results. Fig. 2 shows the framework stages. We want to know how to extract information from collected images over time and how to represent the surface and change in 3D reconstruction. The classifier network loses a lot of geometrical detail through occupancy flow, suffering from dimensionality. Areas outlined in the boundary contained

on the surface have a significant effect on allocations. The method assumes two hypotheses to produce more autonomous, robust, and safe results.

Stage 1. Relying on local information puts certain constraints on the encoding image. Investigating regional and global features to label them and the global context assisted in representing 3D.

Stage 2. The data set includes different variations in the single image where a features filter is applied to the labeled image. The BCNN network was tiny to determine whether this small patch shows evidence of possibility. Fig. 2 shows the proposed stages. Stage 1 learns features to predicate the shape of an object from a given input image. In stage 2, the establishment field is discovered using the already trained modules in this stage.

In training, the system doesn't require any form of compressed supervision. It learns only from unpaired single-image collections and corresponding feature masses. Once discovered, it reconstructs 3D geometry and models dense correspondences from a single image. These features guide the established reconstruction of BCNN in input geometry. The learned point features are concatenated with the 3D point deformations. 3D shapes are rendered into a depth map by projection through the camera matrix to query 3D points on the surface. Every pixel corresponds to that depth map to get the color value 3D point and link texture. We output the texture in 3D location on the shape encoding, and the image encoding to reconstruct 3D.

### Features labels

Image features are detected based on local and global spatial geometry. Many criteria are used to identify features, and there are different ways of using those criteria. Compute image information which distributes first-order spatial derivatives based on orientation. The edges show up as sharp changes in pixel values in the derivative. The edge locations correspond to the minimum and maximum derivatives. Measure the edge sharpness minima and maximum derivatives which are helpful in obtaining magnitudes. The edge locations can be further isolated using local intensity. Corners are detected by first noticing edges where those edges intersect. The corner filter function is detected based on gradients. The features are a number list showing each point position and orientation. A vital feature characteristic is that they are relatively unaffected by scale translation, rotation, and brightness changes. The main idea behind a convolutional neural network is using filters. These filters are responsible for detecting the features or patterns in the image. Many filters pass on the image individually to generate a label. Labeled images are generated by using a filter of  $3 \times 3$  pixels. The total number of parameters in this is only 9, significantly reducing the number of parameters to train. A single layer of a convolutional neural network will use many filters which might detect the corners, edges, and orientation. These filter results will be passed in parallel onto the further layers which label the features associated with the image. Binary classification is a supervised learning method; a training sample includes input and corresponding labels. Data is labeled before training.

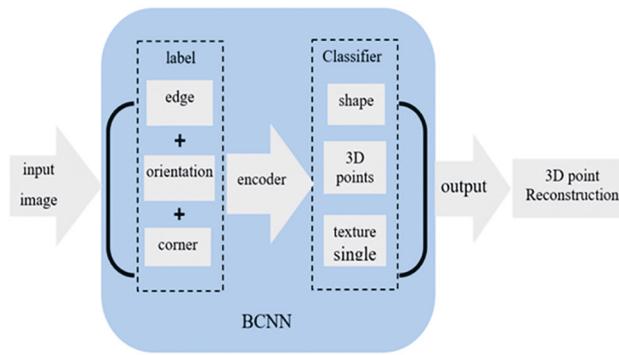


Fig. 2. Proposed stages

A single layer of a convolutional neural network uses many filters. Three filters are used to get three different images. The entire convolution operation gives small values as parameters to train. After model training, these parameter values take a specific value which can detect the associated features from the images.

### BCNN classifier

The classifier considers the object surface as the decision boundary instead of explicitly the total 3D shape representing. The BCNN classifies a point as inside or outside the object depending on classifier function  $f_\theta$  in the following equation:

$$f_\theta(p, x) = R^3x \rightarrow [0, 1],$$

where  $R^3$  is 3D location;  $R^3 \in (p, x)$ ;  $p$  is input point;  $x$  is encoding image conditions;  $[0, 1]$  is occupancy probability;  $\theta$  is neural network parameter.

The occupancy networks update filter feature parameters followed by reconstruction loss. Labels used by the BCNN to detect occupancy points can refine the boundaries. BCNN implicit features models have effective output representations for shape, appearance, materials, and location. Assume the four points are inside, and the rest are outside. Then, iterate at times until the desired resolution is obtained. Fig. 3 shows that the red points are classified as inside, and the blue points are classified as outside. All the blue points have a low occupancy probability close to zero. The red points should be classified as outside and have a high occupancy probability close to one.

The input points network uses the number of points  $K$  equals three times the 3D coordinates. The output for each  $K$  point is the involved probability value. The classification loss function assumes the ground truth occupies the label for each 3D point that trains the equation below. The loss function updates the prediction parameter  $\theta$  while training.

$$\text{Loss}(\theta)_o = \sum_{j=1}^K \text{Loss}(f_\theta(p_{ij}, x_i), o_{ij}),$$

where  $K$  randomly sampled 3D points  $p_{ij}$ ;  $o_{ij}$  observation dataset.

Parameters  $\theta$  takes input 3D location, three coordinates, and a condition vector. The occupancy value of the reconstruction model at time equals zero. Compare this

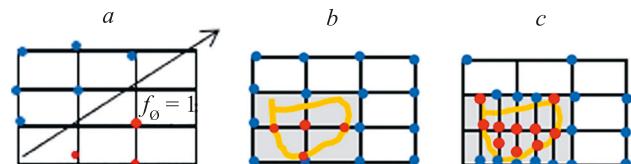


Fig. 3. BCNN occupies probability (a) detect grid points, (b) evaluate voxels and (c) mark surface points

occupancy value to the actual occupancy in observations of the corresponding point location given the image condition corresponding to this label. Fig. 4 represents the shape only at a single point using a 3D occupancy network that can recover geometric detail.

The mapping between the object space and the 3D space points is based on a signed distance-driven functional mapping. A sign-distance generator on the corresponding encodes is used to learn the 3D shape and correspondence field jointly. Signed-distance evaluates the texture field at this predicted surface point and inserts the color value at that corresponding pixel location.

The time limitation of the traditional simple neural network, while dealing with the images, can affect the model performance. The number of operations performed will be significant, and we might need help handling them correctly. Identifying the features from the images permits us to reconstruct the presence of the object automatically in 3D. The BCNN allows the processing of many filters in parallel, significantly reducing time consumption. The only additional time is taken in the filter slice which is still much less than time would have taken by training a simple neural network. Fig. 5 shows the classification that produces labels for an image dataset containing single images. The dataset involves online images of radio, telephone, stairs, sink, car, bin, cabinet, and balcony stone. The results were obtained with a proposed model compared to novel view synthesis baselines.

Fig. 5 shows results that investigated the model power of representation 3D. The first raw is the ground truth example while the second shows label-encoded results. The third raw is to display the overfitting of the texture and object.

The accuracy measurement of the learning model calculated the number of data points detected correctly by comparing the image containing evidence with ground truth. These results are predicted from a single image by combining the implicit representations with primitive-

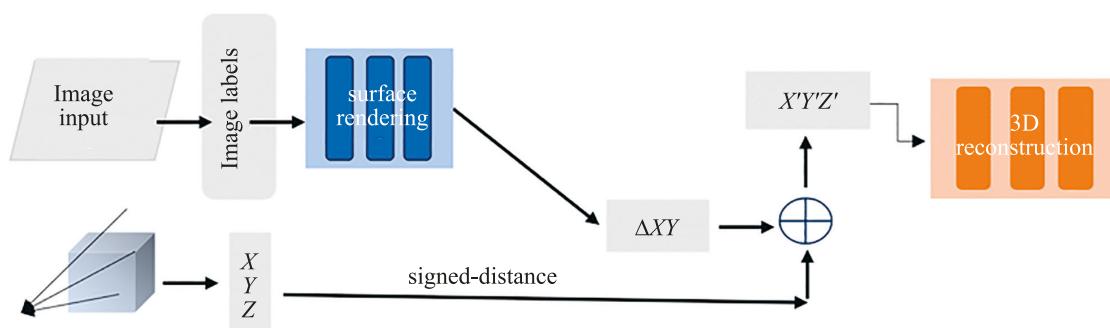


Fig. 4. Mapping 3D point

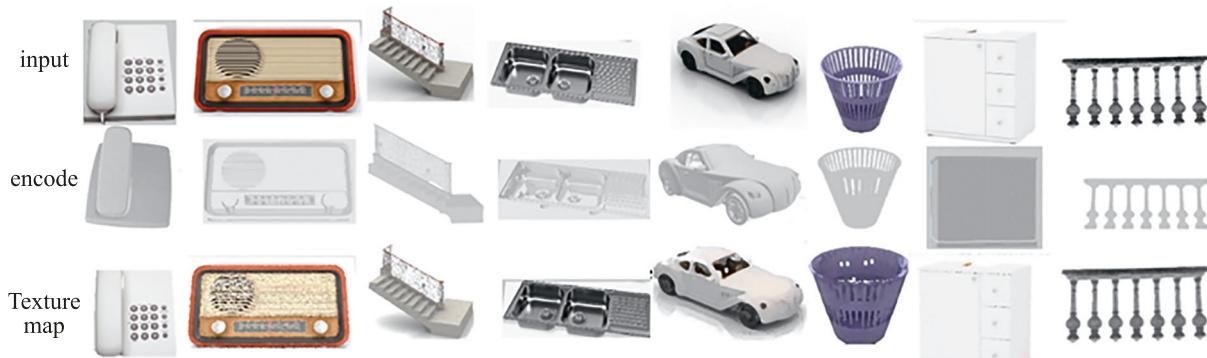


Fig. 5. Reconstruct 3D

based shape models. The high accuracy of the model needs to be corrected in labeling and distinguishing between relevant and irrelevant data. Four measurements are applied to examine the results: precision, recall, chamfer-L1, and Intersection over Union (IoU). Precision is calculated by dividing the predicted label from the overall accurate label. Recall measures the number of relevant elements detected. The recall percentage gives the probability that a randomly selected relevant item from the data set will be detected. Distance chamfer-L1 calculates similarity between set point distance. IoU quantifies the similarity between the predicted bounding and the ground truth. Table displays the model evaluated by accurate measurements.

Precision and recall are calculated to select the suitable model. Recall quantifies the number of positive predictions from all positive examples in the data set. Find the intersection between the two boundaries and the second portion, the union between the ground truth and the predicted. IoU is used for evaluation in the field of object detection. Table displays the results of the generative model showing that latent space interpolations have the same appearance code for different geometry encoding. Smoothing applies acceptable geometric detail structures

to overfit each object individually. In general, the approach time equals the ground truth object and the object deformed in the model; furthermore, the model can overfit multiple objects simultaneously.

## Conclusion

Proposed approaches generally optimize single images to transfer 3D knowledge. BCNN is a simple, fully connected architecture that merges local and global conditioning for real data. It is necessary to input a single image to learn features filter parameters, and then image maps in 3D points. Features are dependent on the 3D location of the points and the viewing direction. Train filters feature parameters using a reconstruction loss function on a data set that has realistic materials. The loss function takes the actual occupancy value and the classifier decision boundary. The loss function is learning weight correspondence information that enhances representing spatially encoded. The approach predicts a latent code for the image that gets reconstructed and overfitted results. Approach characteristics depend on the surface implicitly considered instead of the shape explicitly. 3D convolutions generate a 3D feature volume. The convolution train inputs filter parameters that will detect the associated features from the images. The texture produces field and voxelization of the object. BCNN then queries labels by signed distance from 3D points. The last layers detect the texture and associate it with a particular label in the image. Representing scenes as neural radiance fields uses volume rendering points behind and in front of the surface. The limitation of a fully connected network is that it is sensitive to a large data size, but it is suitable for a single image. The model doesn't require discretization, and arbitrary topology is learned using 2D supervision BCNN. The BCNN is a powerful image model because it performs exceptionally well, and the reconstructions are precise and accurate.

Table. Accuracy measurements

Object	Recall	Precision	Chamfer-L1	IoU
car	0.892	0.874	0.291	0.781
recycle bin	0.901	0.910	0.109	0.690
cabinet	0.868	0.849	0.251	0.589
balcony stone	0.859	0.861	0.194	0.609
telephone	0.871	0.880	0.201	0.698
radio	0.909	0.893	0.099	0.794
stair	0.790	0.802	0.301	0.805
sink	0.793	0.799	0.273	0.789

## References

1. Häming K., Peters G. The structure from-motion reconstruction pipeline — A survey with focus on short image sequences. *Kybernetika*, 2010, vol. 46, no. 5, pp. 926–937.
2. Molenaar M., Eisemann E. Editing compressed high-resolution voxel scenes with attributes. *Computer Graphics Forum*, 2023, vol. 42, no. 2, pp. 235–243. <https://doi.org/10.1111/cgf.14757>

## Литература

1. Häming K., Peters G. The structure from-motion reconstruction pipeline — A survey with focus on short image sequences // *Kybernetika*. 2010. V. 46. N 5. P. 926–937.
2. Molenaar M., Eisemann E. Editing compressed high-resolution voxel scenes with attributes // *Computer Graphics Forum*. 2023. V. 42. N 2. P. 235–243. <https://doi.org/10.1111/cgf.14757>

3. Oechsle M., Peng S., Geiger A. UNISURF: Unifying neural implicit surfaces and radiance fields for multi-view reconstruction. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021, pp. 5569–5579. <https://doi.org/10.1109/iccv48922.2021.00554>
4. Petersen F., Goldluecke B., Borgelt C., Deussen O. GenDR: A generalized differentiable renderer. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 3992–4001. <https://doi.org/10.1109/cvpr52688.2022.00397>
5. Gromniak M., Magg S., Wermter S. Neural field conditioning strategies for 2D semantic segmentation. *Lecture Notes in Computer Science*, 2023, vol. 14255, pp. 520–532. [https://doi.org/10.1007/978-3-031-44210-0\\_42](https://doi.org/10.1007/978-3-031-44210-0_42)
6. Zhao Z., Liu W., Chen X., Zeng X., Wang R., Cheng P., Fu B., Chen T., Yu G., Gao S. Michelangelo: Conditional 3D shape generation based on shape-image-text aligned latent representation. *Advances in Neural Information Processing Systems*, 2023.
7. Su G.-M. Joint forward and backward neural network optimization in image processing. Patent US20230084705A1, 2023.
8. Greff K., Kaufman R.L., Kabra R., Watters N., Burgess C., Zoran D., Matthey L., Botvinick M., Lerchner A. Multi-object representation learning with iterative variational inference. *Proc. of the 36<sup>th</sup> International Conference on Machine Learning*, 2019, pp. 4317–4343.
9. Zanuttigh P., Minto L. Deep learning for 3D shape classification from multiple depth maps. *Proc. of the IEEE International Conference on Image Processing (ICIP)*, 2017, pp. 3615–3619. <https://doi.org/10.1109/icip.2017.8296956>
10. Cheng F., Xiao J., Tillo T., Zhao Y. Global motion information based depth map sequence coding. *Lecture Notes in Computer Science*, 2015, vol. 9314, pp. 721–729. [https://doi.org/10.1007/978-3-319-24075-6\\_69](https://doi.org/10.1007/978-3-319-24075-6_69)
11. Yuan Z., Zhu Y., Li Y., Liu H., Yuan C. Make encoder great again in 3D GAN inversion through geometry and occlusion-aware encoding. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2023, pp. 2437–2447. <https://doi.org/10.1109/iccv51070.2023.00231>
12. Liu F., Huang T., Zhang Q., Yao H., Zhang C., Wan F., Ye Q., Zhou Y. BEAM: Beta distribution ray denoising for multi-view 3D object detection. *arXiv*, 2024, arXiv:2402.03634v1. <https://doi.org/10.48550/arXiv.2402.03634>
13. Wang X., Gupta A. Generative image modeling using style and structure adversarial networks. *Lecture Notes in Computer Science*, 2016, vol. 9908, pp. 318–335. [https://doi.org/10.1007/978-3-319-46493-0\\_20](https://doi.org/10.1007/978-3-319-46493-0_20)
14. Shu C., Deng J., Yu F., Liu Y. 3DPPE: 3D point positional encoding for transformer-based multi-camera 3D object detection. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2023, pp. 3557–3566. <https://doi.org/10.1109/iccv51070.2023.00331>
15. Naselaris T., Olman D., Stansbury K., Ugurbil J., Gallant J.L. A voxel-wise encoding model for early visual areas decodes mental images of remembered scenes. *NeuroImage*, 2015, vol. 105, pp. 215–228. <https://doi.org/10.1016/j.neuroimage.2014.10.018>
16. Du Y.P., Chu R., Tregellas J.R. Enhancing the detection of BOLD signal in fMRI by reducing the partial volume effect. *Computational and Mathematical Methods in Medicine*, 2014. <https://doi.org/10.1155/2014/973972>
17. Wen X., Zhou J., Liu Y.-S., Su H., Dong Z., Han Z. 3D shape reconstruction from 2D images with disentangled attribute flow. *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 3793–3803. <https://doi.org/10.1109/cvpr52688.2022.00378>
18. Oechsle M., Mescheder L., Niemeyer M., Strauss T., Geiger A. Texture fields: Learning texture representations in function space. *Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019, pp. 4530–4539. <https://doi.org/10.1109/iccv.2019.00463>
19. Giannis K., Thon C., Yang G., Kwade A., Schilde C. Predicting 3D particles shapes based on 2D images by using convolutional neural network. *Powder Technology*, 2024, vol. 432, pp. 119122. <https://doi.org/10.1016/j.powtec.2023.119122>
3. Oechsle M., Peng S., Geiger A. UNISURF: Unifying neural implicit surfaces and radiance fields for multi-view reconstruction // Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021. P. 5569–5579. <https://doi.org/10.1109/iccv48922.2021.00554>
4. Petersen F., Goldluecke B., Borgelt C., Deussen O. GenDR: A generalized differentiable renderer // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 3992–4001. <https://doi.org/10.1109/cvpr52688.2022.00397>
5. Gromniak M., Magg S., Wermter S. Neural field conditioning strategies for 2D semantic segmentation // Lecture Notes in Computer Science. 2023. V. 14255. P. 520–532. [https://doi.org/10.1007/978-3-031-44210-0\\_42](https://doi.org/10.1007/978-3-031-44210-0_42)
6. Zhao Z., Liu W., Chen X., Zeng X., Wang R., Cheng P., Fu B., Chen T., Yu G., Gao S. Michelangelo: Conditional 3D shape generation based on shape-image-text aligned latent representation // Advances in Neural Information Processing Systems. 2023.
7. Su G.-M. Joint forward and backward neural network optimization in image processing. Patent US20230084705A1. 2023.
8. Greff K., Kaufman R.L., Kabra R., Watters N., Burgess C., Zoran D., Matthey L., Botvinick M., Lerchner A. Multi-object representation learning with iterative variational inference // Proc. of the 36<sup>th</sup> International Conference on Machine Learning. 2019. P. 4317–4343.
9. Zanuttigh P., Minto L. Deep learning for 3D shape classification from multiple depth maps // Proc. of the IEEE International Conference on Image Processing (ICIP). 2017. P. 3615–3619. <https://doi.org/10.1109/icip.2017.8296956>
10. Cheng F., Xiao J., Tillo T., Zhao Y. Global motion information based depth map sequence coding // Lecture Notes in Computer Science. 2015. V. 9314. P. 721–729. [https://doi.org/10.1007/978-3-319-24075-6\\_69](https://doi.org/10.1007/978-3-319-24075-6_69)
11. Yuan Z., Zhu Y., Li Y., Liu H., Yuan C. Make encoder great again in 3D GAN inversion through geometry and occlusion-aware encoding // Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV). 2023. P. 2437–2447. <https://doi.org/10.1109/iccv51070.2023.00231>
12. Liu F., Huang T., Zhang Q., Yao H., Zhang C., Wan F., Ye Q., Zhou Y. BEAM: Beta distribution ray denoising for multi-view 3D object detection // arXiv. 2024. arXiv:2402.03634v1. <https://doi.org/10.48550/arXiv.2402.03634>
13. Wang X., Gupta A. Generative image modeling using style and structure adversarial networks // Lecture Notes in Computer Science. 2016. V. 9908. P. 318–335. [https://doi.org/10.1007/978-3-319-46493-0\\_20](https://doi.org/10.1007/978-3-319-46493-0_20)
14. Shu C., Deng J., Yu F., Liu Y. 3DPPE: 3D point positional encoding for transformer-based multi-camera 3D object detection // Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV). 2023. P. 3557–3566. <https://doi.org/10.1109/iccv51070.2023.00331>
15. Naselaris T., Olman D., Stansbury K., Ugurbil J., Gallant J.L. A voxel-wise encoding model for early visual areas decodes mental images of remembered scenes // NeuroImage. 2015. V. 105. P. 215–228. <https://doi.org/10.1016/j.neuroimage.2014.10.018>
16. Du Y.P., Chu R., Tregellas J.R. Enhancing the detection of BOLD signal in fMRI by reducing the partial volume effect // Computational and Mathematical Methods in Medicine. 2014. <https://doi.org/10.1155/2014/973972>
17. Wen X., Zhou J., Liu Y.-S., Su H., Dong Z., Han Z. 3D shape reconstruction from 2D images with disentangled attribute flow // Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 3793–3803. <https://doi.org/10.1109/cvpr52688.2022.00378>
18. Oechsle M., Mescheder L., Niemeyer M., Strauss T., Geiger A. Texture fields: Learning texture representations in function space // Proc. of the IEEE/CVF International Conference on Computer Vision (ICCV). 2019. P. 4530–4539. <https://doi.org/10.1109/iccv.2019.00463>
19. Giannis K., Thon C., Yang G., Kwade A., Schilde C. Predicting 3D particles shapes based on 2D images by using convolutional neural network // Powder Technology. 2024. V. 432. P. 119122. <https://doi.org/10.1016/j.powtec.2023.119122>

**Author**

**Sallama Adhab Resen** — PhD, Lecturer, Directorate General of Vocational Education, Baghdad, 1001, Iraq,  57204833765, <https://orcid.org/0009-0007-5044-8857>, salamaresen@gmail.com

Received 13.05.2024

Approved after reviewing 29.08.2024

Accepted 26.09.2024

**Автор**

**Ресен Саллама Адхаб** — PhD, преподаватель, Главное управление профессионального образования, Багдад, 1001, Ирак,  57204833765, <https://orcid.org/0009-0007-5044-8857>, salamaresen@gmail.com

Статья поступила в редакцию 13.05.2024

Одобрена после рецензирования 29.08.2024

Принята к печати 26.09.2024

doi: 10.17586/2226-1494-2024-24-5-849-857

## Obfuscated malware detection using deep neural network with ANOVA feature selection on CIC-MalMem-2022 dataset

Mourad Hadjila<sup>1</sup>✉, Mohammed Merzoug<sup>2</sup>, Wafaa Ferhi<sup>3</sup>, Djillali Moussaoui<sup>4</sup>,  
Al Baraa Bouidaine<sup>5</sup>, Mohammed Hicham Hachemi<sup>6</sup>

<sup>1,2,3,4,5</sup> University of Tlemcen, Tlemcen, 13000, Algeria

<sup>6</sup> University of Oran, Oran, 31000, Algeria

<sup>1</sup> [mhadjila.2009@gmail.com](mailto:mhadjila.2009@gmail.com)✉, <https://orcid.org/0000-0002-6554-3925>

<sup>2</sup> [mohammed.merzoug@univ-tlemcen.dz](mailto:mohammed.merzoug@univ-tlemcen.dz), <https://orcid.org/0009-0002-9117-047X>

<sup>3</sup> [wafaa.ferhi@univ-tlemcen.dz](mailto:wafaa.ferhi@univ-tlemcen.dz), <https://orcid.org/0009-0005-7574-8368>

<sup>4</sup> [djilali.moussaoui@univ-tlemcen.dz](mailto:djilali.moussaoui@univ-tlemcen.dz), <https://orcid.org/0000-0003-3478-263X>

<sup>5</sup> [albaraa.bouidaine@univ-tlemcen.dz](mailto:albaraa.bouidaine@univ-tlemcen.dz), <https://orcid.org/0009-0005-2204-9117>

<sup>6</sup> [hicham.hachemi@univ-usto.dz](mailto:hicham.hachemi@univ-usto.dz), <https://orcid.org/0000-0003-3967-6609>

### Abstract

Malware analysis is the process of dissecting malicious software to understand its functionality, behavior, and potential risks. Artificial Intelligence (AI) and deep learning are ushering in a new era of automated, intelligent, and adaptive malware analysis. This convergence of AI and deep learning promises to revolutionize the way cybersecurity professionals detect, analyze and respond to malware threats. This paper proposed a Deep Neural Network (DNN) model built from features selected by ANalysis Of Variance (ANOVA) F-test (DNN-ANOVA) to increase accuracy by identifying informative features. ANOVA is a feature selection method used for numerical input data when the target variable is categorical. The top  $k$  most relevant features are those whose score values are greater than a certain threshold equal to the ratio between the sum of all features scores and the total number of features. Experiments are conducted on CIC-MalMem-2022 dataset. Malware Analysis is performed using binary classification to detect the presence or absence of malware and multiclass classification to detect not only the malware but also its type. According to the test results, DNN-ANOVA model achieves best values of 100 %, 99.99 %, 99.99 %, and 99.98 % in terms of precision, accuracy, F1-score and recall respectively for binary classification. In addition, DNN-ANOVA outperforms the current works with an overall accuracy rate of 85.83 %, and 73.98 % for family attacks and individual attacks respectively in the case of multiclass classification.

### Keywords

malware detection, deep learning, ANOVA feature selection, binary classification

**For citation:** Hadjila M., Merzoug M., Ferhi W., Moussaoui D., Bouidaine A.B., Hachemi M.H. Obfuscated malware detection using deep neural network with ANOVA feature selection on CIC-MalMem-2022 dataset. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 849–857. doi: 10.17586/2226-1494-2024-24-5-849-857

УДК 004.491

## Обнаружение скрытого вредоносного программного обеспечения с использованием глубокой нейронной сети с выбором признаков ANOVA на наборе данных CIC-MalMem-2022

Мурад Хаджила<sup>1</sup>✉, Мухаммед Мерзуг<sup>2</sup>, Вафа Ферхи<sup>3</sup>, Джилали Муссаи<sup>4</sup>,  
Аль Бараа Байден<sup>5</sup>, Мухаммед Хашеми<sup>6</sup>

<sup>1,2,3,4,5</sup> Университет Тлемсена, Тлемсен, 13000, Алжир

<sup>6</sup> Университет Орана, Оран, 31000, Алжир

<sup>1</sup> mhadjila.2009@gmail.com✉, <https://orcid.org/0000-0002-6554-3925>

<sup>2</sup> mohammed.merzoug@univ-tlemcen.dz, <https://orcid.org/0009-0002-9117-047X>

<sup>3</sup> wafaa.ferhi@univ-tlemcen.dz, <https://orcid.org/0009-0005-7574-8368>

<sup>4</sup> djilali.moussaoui@univ-tlemcen.dz, <https://orcid.org/0000-0003-3478-263X>

<sup>5</sup> albaraa.bouidaine@univ-tlemcen.dz, <https://orcid.org/0009-0005-2204-9117>

<sup>6</sup> hicham.hachemi@univ-usto.dz, <https://orcid.org/0000-0003-3967-6609>

### Аннотация

Анализ вредоносного программного обеспечения включает исследование функциональности, поведения и потенциальных рисков. Искусственный интеллект и глубокое обучение открывают возможности автоматизированного, интеллектуального и адаптивного анализа вредоносного программного обеспечения. В работе предлагается модель глубокой нейронной сети (Deep Neural Network, DNN), созданная на основе признаков, выбранных с помощью F-теста дисперсионного анализа (ANalysis Of VAriance, ANOVA), для повышения точности распознавания путем выявления информативных признаков. DNN-ANOVA представляет собой метод выбора признаков, используемый для анализа числовых входных данных, когда целевая переменная является категориальной. К наиболее релевантным признакам относятся те, значения оценки которых превышают определенный порог, равный отношению суммы оценок всех признаков к общему числу признаков. Эксперименты выполнены на наборе данных CIC-MalMem-2022. Проведен анализ обнаружения или отсутствия вредоносного программного обеспечения с использованием бинарной классификации, а также полиномиальной классификации для определения его типа. Согласно результатам F-теста, модель DNN-ANOVA достигает лучших значений: 100 % — precision, 99,99 % — accuracy, 99, 99 % — F1-score и 99,98 % — recall для бинарной классификации. Кроме того, DNN-ANOVA превосходит текущие работы с общим показателем точности (accuracy) 85,83 % для групповых атак и 73,98 % для индивидуальных атак в случае полиномиальной классификации.

### Ключевые слова

обнаружение вредоносного программного обеспечения, глубокое обучение, выбор признаков ANOVA, бинарная классификация, полиномиальная классификация, набор данных

**Ссылка для цитирования:** Хаджила М., Мерзуг М., Ферхи В., Муссаи Д., Байден А.Б., Хашеми М.Х. Обнаружение скрытого вредоносного программного обеспечения с использованием глубокой нейронной сети с выбором признаков ANOVA на наборе данных CIC-MalMem-2022 // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 849–857 (на англ. яз.). doi: 10.17586/2226-1494-2024-24-5-849-857

### Introduction

Malware, or malicious software, refers to various programs designed to harm devices, steal data, or monitor user activities without their knowledge [1]. It includes worms, viruses, trojans, ransomware, and spyware, which can infect networks and devices [2]. Malware spreads through methods like USB drives, collaboration tools, and drive-by downloads, and is used for purposes, such as stealing passwords [3], accessing confidential data [4], and deceiving governments.

The rapid increase in internet-connected devices has posed significant challenges for malware analysts, researchers, and antivirus companies [5]. Cybercriminals increasingly use the internet for illegal activities, such as financial fraud, data theft, and unauthorized access to systems. In response, researchers have developed new security measures to combat evolving malware. The term “malware” now broadly encompasses any malicious program that compromises the confidentiality, integrity, and availability of systems, networks, or services, whereas

previously all such programs were referred to as computer viruses.

The cyber world is essential to daily life, enabling services like networking, banking, and shopping. However, it also brings significant threats, with malware being one of the most dangerous. The growing volume and complexity of malware make it increasingly difficult to identify and classify [6]. Traditional methods like signature-based detection, along with static and dynamic analysis, are becoming less effective against new malware variants. As a result, there is growing interest and ongoing research in developing more effective methods for malware classification and detection [7].

Artificial Intelligence (AI) has experienced various cycles of interest and decline since its beginnings in the late 1940s, but recent advancements in Machine Learning (ML) and Deep Learning (DL) have solidified its role as a transformative technology. AI now impacts nearly every aspect of life, including information security [8], where it is particularly valuable in combating the vast and costly threat of malware. AI-powered algorithms can analyze

file behavior to detect and classify malware, reducing the workload on security analysts and speeding up detection. Despite its effectiveness, AI has limitations such as false positives, but its role in malware detection is expected to grow as the technology evolves [9].

This paper proposes developing a deep neural network to detect and classify malware using the CIC-MalMem-2022 dataset. To improve accuracy, the study involves a pre-processing step that includes feature selection using the ANalysis Of Variance (ANOVA) F-test to identify the most relevant features. The analysis covers both binary and multiclass classification, targeting family and individual malware attacks. The Python scikit-learn library is used for implementing the feature selection method.

### Related works

Several studies have explored malware analysis using ML. One such study [10] evaluates various ML classifiers for anomaly detection, malware detection, and Intrusion Detection Systems (IDS). The authors also propose a methodology to integrate these ML models into a real-world network security framework, discussing the challenges faced during implementation and the solutions developed to address them. The authors in [11] focus on using ML to detect malware by analyzing memory dumps. They created a new dataset that includes various ransomware types (like BlackCat and REvil) and benign samples. Different ML models were tested, with XGBoost performing the best. The study in [12] introduces a Multi-Attack Detection Framework (MMAD) combining DL methods — Convolutional Neural Network (CNN), Deep Neural Network (DNN), E2E architectures, Recurrent Neural Network (RNN), and Multi Level Platform (MLP) — to detect 11 malware types effectively. Review [13] summarizes and evaluates recent ML and DL contributions to malware detection and suggests future research directions. Sharjeel et al. in [14] propose a DL-based classification method for malware detection in IoT environments. Their methodology includes preprocessing (data cleaning, scaling, etc.), applying an ensemble of CNN and Long Short-Term Memory (LSTM) techniques, and comparing model performance. Xiaofei et al. [15] introduce a new malware detection model using dimensionality reduction and auto-encoder techniques tested on an Android dataset with promising results. Akhtar and Feng [16] developed a malware detection system using Decision Tree (DT), CNN, and Support Vector Machine (SVM). DT achieved the highest accuracy at 99 %, followed by CNN at 98.76 %, and SVM at 96.41 %. Shafin et al. [17] proposed a system combining CNNs and bidirectional LSTMs to detect obfuscated memory malware on resource-constrained devices, using models called CompactCBL and RobustCBL. Mezina and Burget [18] introduced an extended convolutional neural network for classifying obfuscated malware in memory dumps, outperforming traditional classifiers like Decision Tree, SVM, and Random Forest in both binary and multi-class classification.

### ANOVA F-Test Feature Selection

Feature selection is the process of reducing the number of input variables to those that are believed to be most useful for predicting the target variable. The goal is to decrease both the computational cost of modeling and, in many cases, to enhance the model performance [19]. Feature selection is typically straightforward when dealing with real-valued input and output data, as it can be done using methods like Pearson's correlation coefficient. However, it can be more challenging when working with numerical input data and a categorical target variable [20]. When dealing with numerical input data and a categorical target variable, two of the most commonly used feature selection methods are the ANOVA F-test statistic and the mutual information statistic [21]. ANOVA is a parametric statistical hypothesis test for determining whether the means from two or more samples of data come from the same distribution or not. The results of this test can be used for feature selection where those features that are independent of the target variable can be removed from the dataset [19].

## Methodology

### Dataset description

The obfuscated malware dataset is designed to evaluate memory-based detection techniques for concealed malicious software. It includes common malware types like Spyware, Ransomware, and Trojan Horses, making it suitable for testing detection systems [22]. To closely mimic real-world conditions, the dataset uses a debug mode during memory dumps, ensuring the process is not visible, similar to an average user's experience during a malware attack. The dataset is balanced with 50 % benign and 50 % malicious samples, totaling 58,596 records, evenly split between 29,298 benign and 29,298 malicious memory dumps.

The CIC-MalMem-2022 dataset includes three main malware families: Spyware, Trojans, and Ransomware.

— **Spyware.** Infiltrates systems without user consent, monitors activities, and collects data, posing serious risks like identity theft and data breaches [23–25].

— **Trojan.** Disguises itself as legitimate software to deceive users and gain unauthorized access, often used to steal financial information [26, 27].

— **Ransomware.** Encrypts or locks systems, demanding payment to restore access. Typically financially motivated, but can also have political or ideological motives. Prevention and increasing attack difficulty are key protective measures [28–31].

### Data pre-processing

Before starting pre-processing task, it is typically to use a separation of data into training and test set. The training set is into validation set and training set. Test size and validation\_split arguments are set to 0.2 and 0.2 respectively.

In this work, CIC-MalMem-2022 dataset contains 55 features and two targets called "Class" and "Category". "Class" target is used for binary classification while "Category" target is used for multiclass classification.

A bar chart of the feature importance scores for each input feature is created (Fig. 1). This clearly shows that some features might be the most relevant (according to test statistic) when comparing to others and that are the most relevant. Since the used dataset has numerical inputs and a categorical output, we opted for the ANOVA method where a threshold value for selecting the most relevant features is given according to the following formula:

$$\text{Threshold} = \sum_{i=0}^{N-1} \text{score}(i)/N,$$

where  $\text{score}(i)$  is the test statistic value for feature  $i$  (value indicated on the  $y$ -axis of Fig. 1), and  $N$  is the number of features where the value is different to “nan”.

For each dataset feature, score parameter represents the F-statistic calculated as [32]:

$$F = \text{MSB}/\text{MSE},$$

where MSB is the Mean Sum of Squares between the groups, and MSE is the Error Mean Sum of Squares.

MSB is calculated by dividing the Sum of Squares (SS) between the groups by the between group degrees of freedom. MSB is given by the following:

$$\text{MSB} = \text{SS}(Between)/(m - 1),$$

where  $\text{SS}(Between)$  is the Sum of Squares between the group means and the grand mean.

There are  $m - 1$  degrees of freedom associated with the factor of interest when  $m$  groups are compared.

MSE is calculated by dividing the Sum of Squares within the groups by the error degrees of freedom. MSE is given by the following:

$$\text{MSE} = \text{SS}(Error)/(n - m),$$

where  $\text{SS}(Error)$  is the sum of squares between the data and the group means. There are  $n - m$  degrees of freedom of error when  $n$  total data points are collected and  $m$  groups are compared.

The  $k$  most relevant features are calculated with the following equation:

$$k = \{\text{Features} | \text{score} > \text{Threshold}\}.$$

In the dataset, the 16 most relevant features were selected using the ANOVA F-test. These features were retained based on their high relevance scores, as shown in Fig. 1, which also includes a threshold value. Since all features are numerical, feature scaling was essential to normalize the data, making the values comparable. The categorical target variable, “Class” was encoded for binary classification (Benign = 0, Malware = 1). For multiclass classification, the “Category” target values were encoded as 0, 1, 2, and 3, representing benign, trojan, ransomware, and spyware, respectively. For more detailed classification, the “Category” values were encoded from 0 to 15.

#### Proposed architecture

The model is a sequential neural network with four hidden layers. The first hidden layer has 512 neurons and

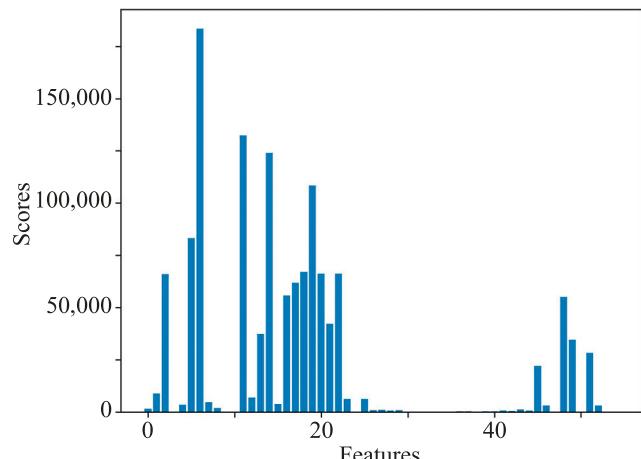


Fig. 1. Bar Chart of the Input Features vs. the ANOVA F-test Feature Importance

expects 16 input variables, while the subsequent layers have 256, 128, and 64 neurons. The output layer varies depending on the classification task: 1 neuron for binary classification, 4 neurons for detecting malware families, and 16 neurons for detecting individual malware types. The RELU activation function is used for hidden layers, with sigmoid for binary output and softmax for multiclass output. L2 regularization is applied to prevent overfitting. The model is trained for 500 epochs with a batch size of 256, using accuracy as the evaluation metric and Adam optimizer with a 0.001 learning rate. The loss functions used are binary cross-entropy and categorical cross-entropy, depending on the task.

## Results and discussion

### Binary classification

The CIC-MalMem-2022 dataset is a balanced dataset with 58,596 records, equally split between benign and malicious samples. It is designed for binary classification, distinguishing between benign and malware instances using the “Class” target variable. The model built for this task achieved near-perfect performance, with 100 % precision, 99.99 % accuracy and F1-score, and 99.98 % recall on the test set. The confusion matrix (Fig. 2) confirms the model effectiveness, showing very few errors in classifying the samples, making it highly reliable for malware detection in cybersecurity.

### Multi-class classification

The CIC-MalMem-2022 dataset, designed for obfuscated malware testing, includes malware families like Trojan Horse, Spyware, and Ransomware, making it suitable for multiclass classification. Two types of multiclass classification are discussed: one for identifying the malware families (Trojan, Spyware, Ransomware) and another for classifying individual attacks within each family.

**Detection of malware families.** The CIC-MalMem-2022 dataset includes a target variable called “Category” which contains values for benign samples and three malware families: trojan, ransomware, and spyware. The malware names were standardized by renaming all entries starting with “ransomware-”, “spyware-”, and “Trojan-” to

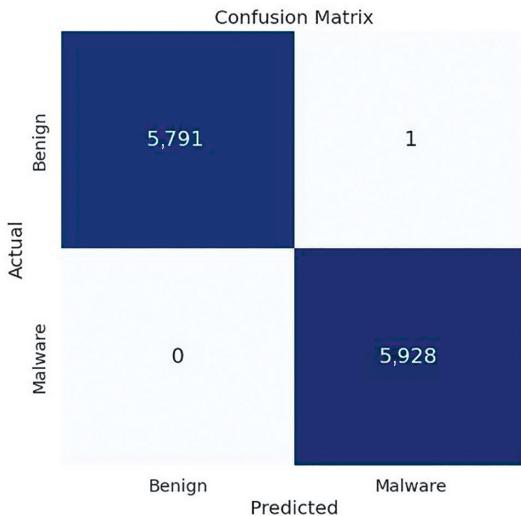


Fig. 2. Confusion matrix for binary classification

Table 1. Number of Instances in case of malware families

Type	Number of instances
Benign	29,298
Spyware	10,020
Ransomware	9,791
Trojan	9,487

“ransomware”, “spyware”, and “trojan”, respectively, resulting in four classes: one for benign samples and three for the malware families.

Table 1 summarizes the occurrence of different types of instances in the “Category” target. The dataset contains 29,298 benign instances, followed by 10,020 spyware instances, 9,791 ransomware instances, and 9,487 trojan instances.

The DNN-ANOVA model achieved an accuracy of 85.83 %, with precision, recall, and F1-score all at 86 %, indicating strong performance and a good balance between precision and recall. The confusion matrix shown in Fig. 3 provides a visual representation of the model accuracy for multiclass classification, specifically in detecting malware families, such as trojan, ransomware, and spyware.

**Detection of individual malwares.** The “Category” target in the CIC-MalMem-2022 dataset includes 58,596 records, evenly split between benign and malicious samples. The malicious records are categorized into three main families — trojan, ransomware, and spyware — each further divided into subfamilies with five types of attacks. Overall, the “Category” target can take 16 values: one for benign samples and 15 for individual malware types. Fig. 4 illustrates the distribution of these malware families.

Table 2 details the number of instances for various types of malware and their subtypes in the “Category” target. The most common type is benign with 29,298 instances. Among the malicious types, “spyware-transponder” is the most frequent with 2,410 instances, followed by “spyware-gator” with 2,200 instances. For ransomware, the most common subtype is “shade” with 2,128 instances, and for trojans, “refroso” is the most prevalent with 2,000 instances.

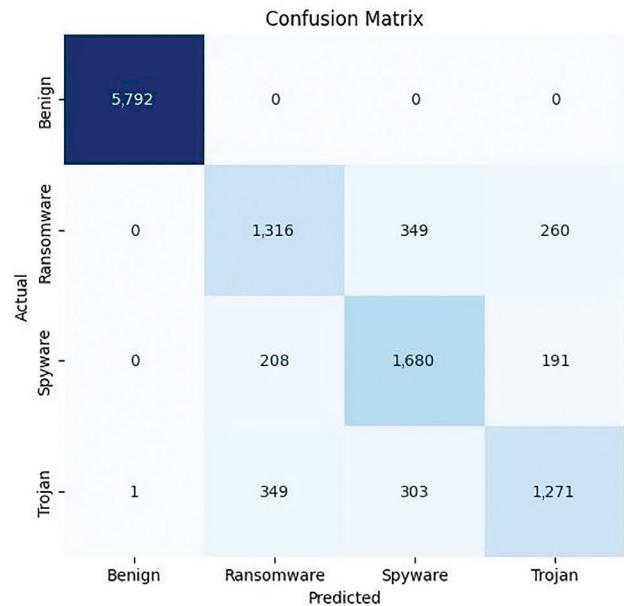
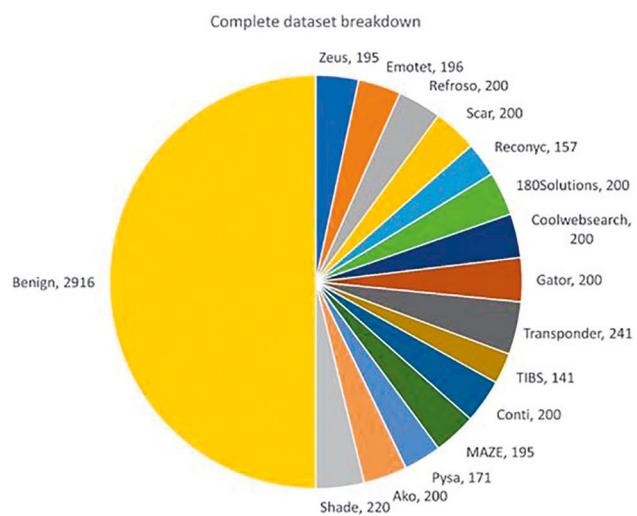


Fig. 3. Confusion matrix for malware families detection

Simulation results show that DNN-ANOVA model achieves accuracy of 73.98 %, and precision, recall, and F1-score, all of 74 %. Fig. 5 shows the confusion matrix for individual attacks detection of the defined dataset.

### Comparative study

This section provides a comparative study of our work with previous research. Table 3 compares Mezina and Burget [18], RobustCBL [17], CompactCBL [17] and DNN-ANOVA (proposed work) with respect to accuracy, precision, recall and F1-score. The DNN-ANOVA model has the highest accuracy, precision, recall, and F1-score

Fig. 4. Complete dataset breakdown<sup>1</sup>

<sup>1</sup> T. Carrier, P. Victor, A. Tekeoglu, and A. H. Lashkari, “CIC-MalMem-2022: Malware Memory Analysis Dataset,” Canadian Institute for Cybersecurity, University of New Brunswick, 2022. [Online]. Available: <https://www.unb.ca/cic/datasets/malmem-2022.html> (accessed: 02.08.2024).

Table 2. Number of Instances in case of individual malwares

Type	Number of instances
Benign	29,298
Spyware-Transponder	2,410
Spyware-Gator	2,200
Spyware-180solutions	2,000
Spyware-CWS	2,000
Spyware-TIBS	1,410
Ransomware-Shade	2,128
Ransomware-Ako	2,000
Ransomware-Conti	1,988
Ransomware-Maze	1,958
Ransomware-Pysa	1,717
Trojan-Refroso	2,000
Trojan-Scar	2,000
Trojan-Emotet	1,967
Trojan-Zeus	1,950
Trojan-Reconyc	1,570

with 85.83 %, 86 %, 86 %, and 86 %, respectively. RobustCBL [17] and CompactCBL [17] have almost the same performance measures, whereas Mezina and Burget has the lowest measures.

The performance metrics of the different models for different classes of malware (malware families) are shown in Table 4. All models have perfect accuracy, precision and recall for the benign class. For the ransomware class, DNN-ANOVA has the highest accuracy, precision, and recall, whereas Mezina and Burget [18] has the lowest accuracy, precision, and recall. For the spyware class, DNN-ANOVA has the highest accuracy, precision, and recall, while RobustCBL [17] has the lowest accuracy, precision, and recall. Regarding the trojan category, DNN-ANOVA has the highest precision and shares with RobustCBL [17] the best F1-score, though it falls slightly behind in recall. Conversely, Mezina and Burget [18] record the minimal scores in accuracy, precision, and recall for this class.

Table 5 shows the performance metrics for different models in the case of individual malwares detection. The comparison is made in terms of accuracy, precision, recall, and F1-score. DNN-ANOVA has the highest accuracy, precision, recall, and F1-score at 73.98 %, 74 %, 74 %, and 74 %, respectively. Robust-CBL [17] and CompactCBL [17] have lower performance metrics, with RobustCBL [17] having slightly higher precision, recall, and F1-score than CompactCBL [17].

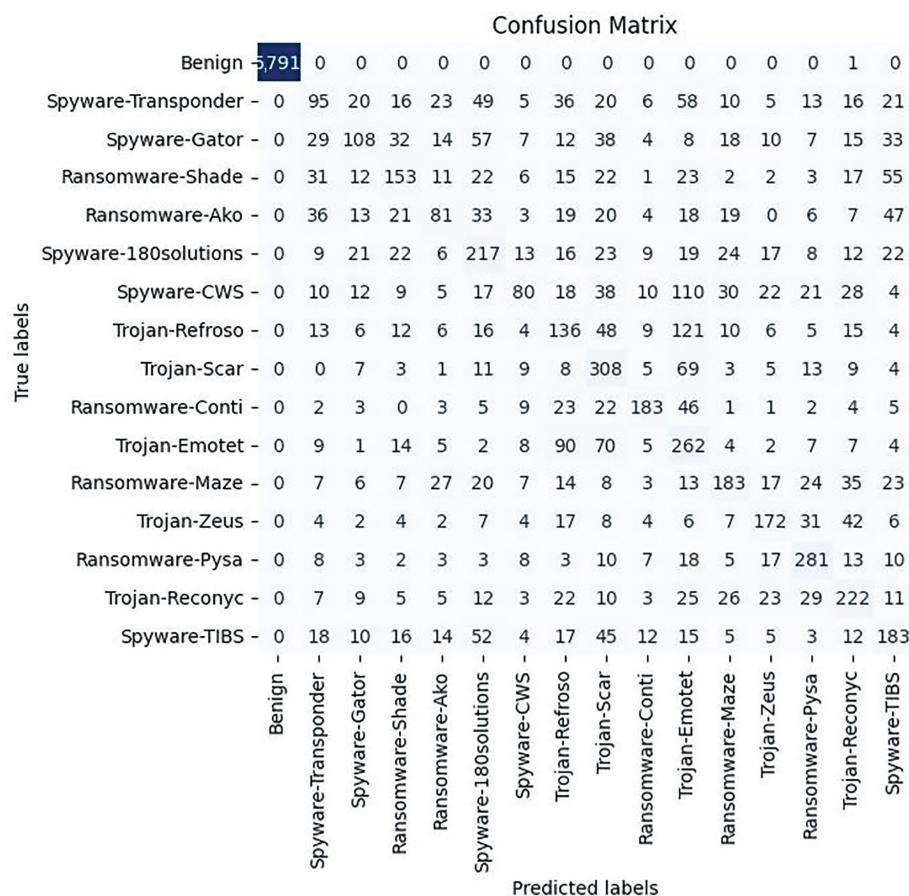


Fig. 5. Confusion matrix for individual malware detection

Table 3. Attack family detection performance comparison, %

	Accuracy	Precision	Recall	F1-score
Mezina & Burget [18]	83.53	75.79	75.18	75.13
RobustCBL [17]	84.56	85.00	85.00	84.00
CompactCBL [17]	84.22	84.00	84.00	84.00
DNN-ANOVA	85.83	86.00	86.00	86.00

Table 4. Attack families detection performance for each class, %

Class	Mezina & Burget [18]			RobustCBL [17]			DNN-ANOVA		
	Precision	Recall	F1-score	Precision	Recall	F1-score	Precision	Recall	F1-score
Benign	100	100	100	100	100	100	100	100	100
Ransom-ware	62	66	64	67	62	64	70	68	69
Spyware	67	76	71	69	77	73	72	81	76
Trojan	73	57	64	71	67	70	74	66	70

Table 5. Attack family detection performance comparison, %

	Accuracy	Precision	Recall	F1-score
RobustCBL [17]	72.60	73.00	73.00	72.00
CompactCBL [17]	71.42	72.00	71.00	71.00
DNN-ANOVA	73.98	74.00	74.00	74.00

## Conclusion

In this paper, a Deep Neural Network was proposed to detect and classify malwares. A pre-processing task was necessary to first select the most relevant features using ANalysis Of Variance (ANOVA) F-test feature selection strategy where the  $k$  most relevant features are those whose score values exceeds a certain threshold evaluated as the ratio between the sum of all features scores and the total number of features. Once features are selected, target variable was encoded. Malware analysis is done either by binary classification to determine if there is malware, or by multiclass classification to detect not only the malware but

also its type. The proposed model is trained and assessed using CIC-MalMem-2022 dataset. To demonstrate the efficiency of the suggested model, its performance has been studied and compared with other previous research. Results reveal that the suggested model outperforms previous works with 85.83% accuracy, 86 % precision, 86 % recall, and 86 % F1-score when dealing with malware families, and outperforms other works with 73.98 % accuracy, 74 % precision, 74 % recall, and 74 % F1-score in the case of individual attacks detection. Our future research will focus on refining the model by applying graph neural network and deep reinforcement learning.

## References

- Kramer S., Bradfield J.C. A general definition of malware. *Journal in Computer Virology*, 2010, vol. 6, no. 2, pp. 105–114. <https://doi.org/10.1007/s11416-009-0137-1>
- Li C., Gaudiot J.L. Detecting malicious attacks exploiting hardware vulnerabilities using performance counters. *Proc. of the 2019 IEEE 43rd Annual Computer Software and Applications Conference (COMPSAC)*. V. 1, 2019, pp. 588–597. <https://doi.org/10.1109/compsac2019.00090>
- Sinanovic H., Mrdovic S. Analysis of Mirai malicious software. *Proc. of the 25th International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, 2017, pp. 1–5. <https://doi.org/10.23919/softcom.2017.8115504>
- Singh R., Kumar H., Singla R.K., Ketti R.R. Internet attacks and intrusion detection system: A review of the literature. *Online Information Review*, 2017, vol. 41, no. 2, pp. 171–184. <https://doi.org/10.1108/oir-12-2015-0394>
- Yadav B., Tokekar S. Deep learning in malware identification and classification. *Malware Analysis Using Artificial Intelligence and Deep Learning*. Springer, Cham, 2021, pp. 163–205. [https://doi.org/10.1007/978-3-030-62582-5\\_6](https://doi.org/10.1007/978-3-030-62582-5_6)

## Литература

- Kramer S., Bradfield J.C. A general definition of malware // Journal in Computer Virology. 2010. V. 6. N 2. P. 105–114. <https://doi.org/10.1007/s11416-009-0137-1>
- Li C., Gaudiot J.L. Detecting malicious attacks exploiting hardware vulnerabilities using performance counters // Proc. of the 2019 IEEE 43rd Annual Computer Software and Applications Conference (COMPSAC). V. 1. 2019. P. 588–597. <https://doi.org/10.1109/compsac2019.00090>
- Sinanovic H., Mrdovic S. Analysis of Mirai malicious software // Proc. of the 25th International Conference on Software, Telecommunications and Computer Networks (SoftCOM). 2017. P. 1–5. <https://doi.org/10.23919/softcom.2017.8115504>
- Singh R., Kumar H., Singla R.K., Ketti R.R. Internet attacks and intrusion detection system: A review of the literature // Online Information Review. 2017. V. 41. N 2. P. 171–184. <https://doi.org/10.1108/oir-12-2015-0394>
- Yadav B., Tokekar S. Deep learning in malware identification and classification // Malware Analysis Using Artificial Intelligence and Deep Learning. Springer, Cham, 2021. P. 163–205. [https://doi.org/10.1007/978-3-030-62582-5\\_6](https://doi.org/10.1007/978-3-030-62582-5_6)

6. Kertysova K., Frinking E., van den Dool K., Maricic A., Bhattacharyya K. *Cybersecurity: Ensuring awareness and resilience of the private sector across Europe in face of mounting cyber risks-Study*. Bruxelles, Belgium: European Economic and Social Committee, 2018.
7. Gopinath M., Sethuraman S.C. A comprehensive survey on deep learning based malware detection techniques. *Computer Science Review*, 2023, vol. 47, pp. 100529. <https://doi.org/10.1016/j.cosrev.2022.100529>
8. Faruk M.J.H., Shahriar H., Valero M., Barsha F.L., Sobhan S., Khan M.A., Whitman M., Cuzzocrea A., Lo D., Rahman A., Wu F. Malware detection and prevention using artificial intelligence techniques. *Proc. of the IEEE International Conference on Big Data (Big Data)*, 2021, pp. 5369–5377. <https://doi.org/10.1109/bigdata52589.2021.9671434>
9. Vigna G. How AI will help in the fight against malware. *Retrieved from TechBeacon*, 2020.
10. Schmitt M. Securing the Digital World: Protecting smart infrastructures and digital industries with Artificial Intelligence (AI)-enabled malware and intrusion detection. *Journal of Industrial Information Integration*, 2023, vol. 36, pp. 100520. <https://doi.org/10.1016/j.jii.2023.100520>
11. Aljabri M., Alhaidari F., Albuainain A., Alrashidi S., Alansari J., Alqahtani W., Alshaya J. Ransomware detection based on machine learning using memory features. *Egyptian Informatics Journal*, 2024, vol. 25, pp. 100445. <https://doi.org/10.1016/j.eij.2024.100445>
12. Ababneh M., Aljarrah A. Cybersecurity: Malware multi-attack detector on android-based devices using deep learning methods. *Journal of Theoretical and Applied Information Technology*, 2024, vol. 102, no. 1, pp. 144–166.
13. Majid A.A.M., Alshaibi A.J., Kostyuchenko E., Shelupanov A. A review of artificial intelligence based malware detection using deep learning. *Materials Today: Proceedings*, 2023, vol. 80, part 3, pp. 2678–2683. <https://doi.org/10.1016/j.matpr.2021.07.012>
14. Riaz S., Latif S., Usman S.M., Ullah S.S., Algarni A.D., Yasin A., Anwar A., Elmannai H., Hussain S. Malware Detection in Internet of Things (IoT) devices using deep learning. *Sensors*, 2022, vol. 22, no. 23, pp. 9305. <https://doi.org/10.3390/s22239305>
15. Xing X., Jin X., Elahi H., Jiang H., Wang G. A malware detection approach using autoencoder in deep learning. *IEEE Access*, 2022, vol. 10, pp. 25696–25706. <https://doi.org/10.1109/access.2022.3155695>
16. Ucci D., Aniello L., Baldoni R. Survey of machine learning techniques for malware analysis. *Computers & Security*, 2019, vol. 81, pp. 123–147. <https://doi.org/10.1016/j.cose.2018.11.001>
17. Shafin S.S., Karmakar G., Mareels I. Obfuscated memory malware detection in resource-constrained IoT devices for smart city applications. *Sensors*, 2023, vol. 23, no. 11, pp. 5348. <https://doi.org/10.3390/s23115348>
18. Mezina A., Burget R. Obfuscated malware detection using dilated convolutional network. *Proc. of the 14<sup>th</sup> International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)*, 2022, pp. 110–115. <https://doi.org/10.1109/icumt57764.2022.9943443>
19. Brownlee J. How to perform feature selection with numerical input data. *Machine Learning Mastery*, 2020.
20. Brownlee J. How to choose a feature selection method for machine learning. *Machine Learning Mastery*, 2019.
21. Cai J., Luo J., Wang S., Yang S. Feature selection in machine learning: A new perspective. *Neurocomputing*, 2018, vol. 300, pp. 70–79. <https://doi.org/10.1016/j.neucom.2017.11.077>
22. Payton A.M. A review of spyware campaigns and strategies to combat them. *Proc. of the 3<sup>rd</sup> Annual Conference on Information Security Curriculum Development*, 2006, pp. 136–141. <https://doi.org/10.1145/1231047.1231077>
23. Carrier T., Victor P., Tekeoglu A., Lashkari A. Detecting obfuscated malware using memory feature engineering. *Proc. of the 8<sup>th</sup> International Conference on Information Systems Security and Privacy ICISSP*. V. 1, 2022, pp. 177–188. <https://doi.org/10.5220/0010908200003120>
24. Mallikarjunan K.N., Preethi S.R., Selvalakshmi S., Nithish N. Detection of spyware in software using virtual environment. *Proc. of the 3<sup>rd</sup> International Conference on Trends in Electronics and Informatics (ICOEI)*, 2019, pp. 1138–1142. <https://doi.org/10.1109/icoei.2019.8862547>
25. Jonasson D., Sigholm J. What is Spyware?. TDDC03 Projects, Department of Computer and Information Science. Sewden: Linkopings University, 2005.
6. Kertysova K., Frinking E., van den Dool K., Maricic A., Bhattacharyya K. *Cybersecurity: Ensuring awareness and resilience of the private sector across Europe in face of mounting cyber risks-Study*. Bruxelles, Belgium: European Economic and Social Committee, 2018.
7. Gopinath M., Sethuraman S.C. A comprehensive survey on deep learning based malware detection techniques // *Computer Science Review*. 2023. V. 47. P. 100529. <https://doi.org/10.1016/j.cosrev.2022.100529>
8. Faruk M.J.H., Shahriar H., Valero M., Barsha F.L., Sobhan S., Khan M.A., Whitman M., Cuzzocrea A., Lo D., Rahman A., Wu F. Malware detection and prevention using artificial intelligence techniques // *Proc. of the IEEE International Conference on Big Data (Big Data)*. 2021. P. 5369–5377. <https://doi.org/10.1109/bigdata52589.2021.9671434>
9. Vigna G. How AI will help in the fight against malware // Retrieved from TechBeacon. 2020.
10. Schmitt M. Securing the Digital World: Protecting smart infrastructures and digital industries with Artificial Intelligence (AI)-enabled malware and intrusion detection // *Journal of Industrial Information Integration*. 2023. V. 36. P. 100520. <https://doi.org/10.1016/j.jii.2023.100520>
11. Aljabri M., Alhaidari F., Albuainain A., Alrashidi S., Alansari J., Alqahtani W., Alshaya J. Ransomware detection based on machine learning using memory features // *Egyptian Informatics Journal*. 2024. V. 25. P. 100445. <https://doi.org/10.1016/j.eij.2024.100445>
12. Ababneh M., Aljarrah A. Cybersecurity: Malware multi-attack detector on android-based devices using deep learning methods // *Journal of Theoretical and Applied Information Technology*. 2024. V. 102, N 1. P. 144–166.
13. Majid A.A.M., Alshaibi A.J., Kostyuchenko E., Shelupanov A. A review of artificial intelligence based malware detection using deep learning // *Materials Today: Proceedings*. 2023. V. 80. Part 3. P. 2678–2683. <https://doi.org/10.1016/j.matpr.2021.07.012>
14. Riaz S., Latif S., Usman S.M., Ullah S.S., Algarni A.D., Yasin A., Anwar A., Elmannai H., Hussain S. Malware Detection in Internet of Things (IoT) devices using deep learning // *Sensors*. 2022. V. 22, N 23. P. 9305. <https://doi.org/10.3390/s22239305>
15. Xing X., Jin X., Elahi H., Jiang H., Wang G. A malware detection approach using autoencoder in deep learning // *IEEE Access*. 2022. V. 10. P. 25696–25706. <https://doi.org/10.1109/access.2022.3155695>
16. Ucci D., Aniello L., Baldoni R. Survey of machine learning techniques for malware analysis // *Computers & Security*. 2019. V. 81. P. 123–147. <https://doi.org/10.1016/j.cose.2018.11.001>
17. Shafin S.S., Karmakar G., Mareels I. Obfuscated memory malware detection in resource-constrained IoT devices for smart city applications // *Sensors*. 2023. V. 23. N 11. P. 5348. <https://doi.org/10.3390/s23115348>
18. Mezina A., Burget R. Obfuscated malware detection using dilated convolutional network // *Proc. of the 14<sup>th</sup> International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)*. 2022. P. 110–115. <https://doi.org/10.1109/icumt57764.2022.9943443>
19. Brownlee J. How to perform feature selection with numerical input data // *Machine Learning Mastery*. 2020.
20. Brownlee J. How to choose a feature selection method for machine learning // *Machine Learning Mastery*. 2019.
21. Cai J., Luo J., Wang S., Yang S. Feature selection in machine learning: A new perspective // *Neurocomputing*. 2018. V. 300. P. 70–79. <https://doi.org/10.1016/j.neucom.2017.11.077>
22. Payton A.M. A review of spyware campaigns and strategies to combat them // *Proc. of the 3<sup>rd</sup> Annual Conference on Information Security Curriculum Development*. 2006. P. 136–141. <https://doi.org/10.1145/1231047.1231077>
23. Carrier T., Victor P., Tekeoglu A., Lashkari A. Detecting obfuscated malware using memory feature engineering // *Proc. of the 8<sup>th</sup> International Conference on Information Systems Security and Privacy ICISSP*. V. 1, 2022. P. 177–188. <https://doi.org/10.5220/0010908200003120>
24. Mallikarjunan K.N., Preethi S.R., Selvalakshmi S., Nithish N. Detection of spyware in software using virtual environment // *Proc. of the 3<sup>rd</sup> International Conference on Trends in Electronics and Informatics (ICOEI)*. 2019, pp. 1138–1142. <https://doi.org/10.1109/icoei.2019.8862547>
25. Jonasson D., Sigholm J. What is Spyware?. TDDC03 Projects, Department of Computer and Information Science. Sewden: Linkopings University, 2005.

25. Jonasson D., Sigholm J. *What is Spyware?*. *TDDC03 Projects, Department of Computer and Information Science*. Sewden, Linkopings University, 2005.
26. Pelchen-Matthews A., Raposo G., Marsh M. Endosomes, exosomes and Trojan viruses // Trends in Microbiology. 2004. V. 12. N 7. P. 310–316. <https://doi.org/10.1016/j.tim.2004.05.004>
27. Liu Y., Mondal A., Chakraborty A., Zuzak M., Jacobsen N., Xing D., Srivastava A. A survey on neural trojans. *Proc. of the 21<sup>st</sup> International Symposium on Quality Electronic Design (ISQED)*, 2020, pp. 33–39. <https://doi.org/10.1109/isqed48828.2020.9137011>
28. Brewer R. Ransomware attacks: detection, prevention and cure // *Network Security*. 2016, vol. 2016, no. 9, pp. 5–9. [https://doi.org/10.1016/s1353-4858\(16\)30086-1](https://doi.org/10.1016/s1353-4858(16)30086-1)
29. Tuttle H. Ransomware attackers turn to double extortion // *Risk Management*. 2021, vol. 68, no. 2, pp. 8–9.
30. Nershi K., Grossman S. Assessing the Political Motivations Behind Ransomware Attacks. *SSRN Electronic Journal*, 2023. <https://doi.org/10.2139/ssrn.4507111>
31. Casas P., Blancas J., Villanueva A. Ransomware Report 2023: targets, motives, and trends. *Outpost24*. 07 Feb. 2023. Available: <https://outpost24.com/blog/ransomware-report-2023-targets-motives-and-trends/> (accessed: 01.08.2024).
32. Sawyer S.F. Analysis of variance: the fundamental concepts. *Journal of Manual & Manipulative Therapy*, 2009, vol. 17, no. 2, pp. 27E–38E. <https://doi.org/10.1179/jmt.2009.17.2.27e>
26. Pelchen-Matthews A., Raposo G., Marsh M. Endosomes, exosomes and Trojan viruses // Trends in Microbiology. 2004. V. 12. N 7. P. 310–316. <https://doi.org/10.1016/j.tim.2004.05.004>
27. Liu Y., Mondal A., Chakraborty A., Zuzak M., Jacobsen N., Xing D., Srivastava A. A survey on neural trojans // Proc. of the 21<sup>st</sup> International Symposium on Quality Electronic Design (ISQED). 2020. P. 33–39. <https://doi.org/10.1109/isqed48828.2020.9137011>
28. Brewer R. Ransomware attacks: detection, prevention and cure // Network Security. 2016. V. 2016. N 9. P. 5–9. [https://doi.org/10.1016/s1353-4858\(16\)30086-1](https://doi.org/10.1016/s1353-4858(16)30086-1)
29. Tuttle H. Ransomware attackers turn to double extortion // Risk Management. 2021. V. 68. N 2. P. 8–9.
30. Nershi K., Grossman S. Assessing the Political Motivations Behind Ransomware Attacks // SSRN Electronic Journal. 2023. <https://doi.org/10.2139/ssrn.4507111>
31. Casas P., Blancas J., Villanueva A. Ransomware Report 2023: targets, motives, and trends // Outpost24. 07 Feb. 2023 [Электронный ресурс]. URL: <https://outpost24.com/blog/ransomware-report-2023-targets-motives-and-trends/> (дата обращения: 01.08.2024).
32. Sawyer S.F. Analysis of variance: the fundamental concepts // Journal of Manual & Manipulative Therapy. 2009. V. 17. N 2. P. 27E–38E. <https://doi.org/10.1179/jmt.2009.17.2.27e>

## Authors

**Mourad Hadjila** — D.Sc., Lecturer-Researcher, University of Tlemcen, Tlemcen, 13000, Algeria, [sc 56440246000](https://orcid.org/0000-0002-6554-3925), <https://orcid.org/0000-0002-6554-3925>, [mhadjila.2009@gmail.com](mailto:mhadjila.2009@gmail.com)

**Mohammed Merzoug** — D.Sc., Lecturer-Researcher, University of Tlemcen, University of Tlemcen, Tlemcen, 13000, Algeria, [sc 55309175500](https://orcid.org/0009-0002-9117-047X), <https://orcid.org/0009-0002-9117-047X>, [mohammed.merzoug@univ-tlemcen.dz](mailto:mohammed.merzoug@univ-tlemcen.dz)

**Wafaa Ferhi** — PhD Student, University of Tlemcen, Tlemcen, 13000, Algeria, <https://orcid.org/0009-0005-7574-8368>, [wafaa.ferhi@univ-tlemcen.dz](mailto:wafaa.ferhi@univ-tlemcen.dz)

**Djillali Moussaoui** — D.Sc., Lecturer-Researcher, University of Tlemcen, Tlemcen, 13000, Algeria, [sc 56360232600](https://orcid.org/0000-0003-3478-263X), <https://orcid.org/0000-0003-3478-263X>, [djilali.moussaoui@univ-tlemcen.dz](mailto:djilali.moussaoui@univ-tlemcen.dz)

**Al Baraa Bouidaine** — PhD Student, University of Tlemcen, Tlemcen, 13000, Algeria, <https://orcid.org/0009-0005-2204-9117>, [albaraa.bouidaine@univ-tlemcen.dz](mailto:albaraa.bouidaine@univ-tlemcen.dz)

**Mohammed Hicham Hachemi** — D.Sc., Lecturer-Researcher, University of Oran, Oran, 31000, Algeria, [sc 57196009731](https://orcid.org/0000-0003-3967-6609), <https://orcid.org/0000-0003-3967-6609>, [hicham.hachemi@univ-usto.dz](mailto:hicham.hachemi@univ-usto.dz)

Received 27.10.2023

Approved after reviewing 13.08.2024

Accepted 25.09.2024

## Авторы

**Хаджила Мурад** — доктор наук, преподаватель-исследователь, Университет Тлемсена, Тлемсен, 13000, Алжир, [sc 56440246000](https://orcid.org/0000-0002-6554-3925), <https://orcid.org/0000-0002-6554-3925>, [mhadjila.2009@gmail.com](mailto:mhadjila.2009@gmail.com)

**Мерзуг Мухаммед** — доктор наук, преподаватель-исследователь, Университет Тлемсена, Тлемсен, 13000, Алжир, [sc 55309175500](https://orcid.org/0009-0002-9117-047X), <https://orcid.org/0009-0002-9117-047X>, [mohammed.merzoug@univ-tlemcen.dz](mailto:mohammed.merzoug@univ-tlemcen.dz)

**Ферхи Вафа** — аспирант, Университет Тлемсена, Тлемсен, 13000, Алжир, <https://orcid.org/0009-0005-7574-8368>, [wafaa.ferhi@univ-tlemcen.dz](mailto:wafaa.ferhi@univ-tlemcen.dz)

**Муссауи Джалали** — доктор наук, преподаватель-исследователь, Университет Тлемсена, Тлемсен, 13000, Алжир, [sc 56360232600](https://orcid.org/0000-0003-3478-263X), <https://orcid.org/0000-0003-3478-263X>, [djilali.moussaoui@univ-tlemcen.dz](mailto:djilali.moussaoui@univ-tlemcen.dz)

**Буден Аль Бараа** — аспирант, Университет Тлемсена, Тлемсен, 13000, Алжир, <https://orcid.org/0009-0005-2204-9117>, [albaraa.bouidaine@univ-tlemcen.dz](mailto:albaraa.bouidaine@univ-tlemcen.dz)

**Хашеми Мухаммед Хишам** — доктор наук, преподаватель-исследователь, Университет Орана, Оран, 31000, Алжир, [sc 57196009731](https://orcid.org/0000-0003-3967-6609), <https://orcid.org/0000-0003-3967-6609>, [hicham.hachemi@univ-usto.dz](mailto:hicham.hachemi@univ-usto.dz)

Статья поступила в редакцию 27.10.2023

Одобрена после рецензирования 13.08.2024

Принята к печати 25.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

## МАТЕМАТИЧЕСКОЕ И КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ MODELING AND SIMULATION

doi: 10.17586/2226-1494-2024-24-5-858-865  
УДК 621.313

### Карта намагничивания вентильно-индукторного электродвигателя: экспериментальный подход

Андрей Михайлович Яременко<sup>1</sup>✉, Галина Львовна Демидова<sup>2</sup>,  
Алла Алексеевна Сорокина<sup>3</sup>, Александр Геннадьевич Маматов<sup>4</sup>,  
Андрей Николаевич Богданов<sup>5</sup>, Алексей Сергеевич Анучин<sup>6</sup>

<sup>1,2,3,4</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>5,6</sup> Московский энергетический институт, Москва, 111250, Российская Федерация

<sup>1</sup> amyaremenko@itmo.ru✉, <https://orcid.org/0009-0007-7220-3957>

<sup>2</sup> demidova@itmo.ru, <https://orcid.org/0000-0003-2786-715X>

<sup>3</sup> 265957@niuitmo.ru, <https://orcid.org/0009-0001-7466-4673>

<sup>4</sup> amamatov@itmo.ru, <https://orcid.org/0000-0002-1887-3059>

<sup>5</sup> anbogdanov@itmo.ru, <https://orcid.org/0009-0007-3858-5859>

<sup>6</sup> anuchin.alecksey@itmo.ru, <https://orcid.org/0000-0002-1019-756X>

#### Аннотация

**Введение.** В настоящее время вентильно-индукторная электрическая машина рассматривается как наиболее перспективный вид электромеханического преобразователя энергии без постоянных магнитов для работы со скоростями ниже номинальных значений. Для управления вентильно-индукторным электродвигателем с минимальными пульсациями момента необходимо формировать токи фаз в соответствии с угловым положением ротора в функции потокосцепления фазы от тока и положения ротора. Карты намагничивания также используются в системах управления с косвенным определением положения ротора. **Метод.** В работе представлена экспериментальная методика получения карты намагничивания вентильно-индукторного электродвигателя. Приведен расчет потокосцепления для каждого угла положения ротора электрической машины. Предложенное решение предусматривает механическую блокировку ротора вентильно-индукторного двигателя и периодическую подачу напряжения при помощи полупроводникового преобразователя на одну из фаз электродвигателя для получения информации о фазном токе и напряжении. **Основные результаты.** С использованием представленного экспериментального подхода получены соотношения между потокосцеплением, током фазы и углом поворота ротора. Показано, что данное решение может быть использовано для точного определения карты намагничивания вентильно-индукторного двигателя. **Обсуждение.** Представленную методику целесообразно использовать при проектировании системы управления с прогнозированием.

#### Ключевые слова

вентильно-индукторный двигатель, карта намагничивания, потокосцепление, идентификация, электрическая машина

**Ссылка для цитирования:** Яременко А.М., Демидова Г.Л., Сорокина А.А., Маматов А.Г., Богданов А.Н., Анучин А.С. Карта намагничивания вентильно-индукторного электродвигателя: экспериментальный подход // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 858–865.  
doi: 10.17586/2226-1494-2024-24-5-858-865

## Switched reluctance motor flux linkage characteristic: experimental approach

Andrey M. Yaremenko<sup>1</sup>, Galina L. Demidova<sup>2</sup>, Alla A. Sorokina<sup>3</sup>,  
Aleksandr G. Mamatov<sup>4</sup>, Andrey N. Bogdanov<sup>5</sup>, Alecksey S. Anuchin<sup>6</sup>

<sup>1,2,3,4</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>5,6</sup> Moscow Power Engineering Institute, Moscow, 111250, Russian Federation

<sup>1</sup> amyaremenko@itmo.ru, <https://orcid.org/0009-0007-7220-3957>

<sup>2</sup> demidova@itmo.ru, <https://orcid.org/0000-0003-2786-715X>

<sup>3</sup> 265957@niuitmo.ru, <https://orcid.org/0009-0001-7466-4673>

<sup>4</sup> amamatov@itmo.ru, <https://orcid.org/0000-0002-1887-3059>

<sup>5</sup> anbogdanov@itmo.ru, <https://orcid.org/0009-0007-3858-5859>

<sup>6</sup> anuchin.alecksey@itmo.ru, <https://orcid.org/0000-0002-1019-756X>

### Abstract

Currently, switched reluctance motors are considered the most promising type of electromechanical energy converter without permanent magnets, especially for operations at sub-nominal speeds. To control of a switched reluctance motor to minimize torque ripple requires the regulation of phase currents based on the rotor angular position, utilizing the flux linkage as a function of both current and rotor angle. The flux linkage characteristic is essential in control systems that indirectly determine the rotor position. The paper presents an experimental methodology for deriving the flux linkage characteristic of a switched reluctance motor. The calculation of flux linkage for each rotor position angle of the electric machine is provided. The proposed methodology involves mechanically locking the rotor and periodically applying voltage to one of the motor phases using a power converter to gather data on phase current and voltage. Using the proposed experimental methodology, the relationships between flux linkage, phase current, and rotor angle were obtained. The results demonstrate that this methodology can be effectively utilized to accurately determine the flux linkage characteristic of a switched reluctance motor. The experimental methodology proposed in this paper can be employed to generate the flux linkage characteristic of a switched reluctance motor. This approach is particularly advantageous for designing model predictive control systems.

### Keywords

switched reluctance motor, flux linkage characteristic, identification, flux model, electric motor

**For citation:** Yaremenko A.M., Demidova G.L., Sorokina A.A., Mamatov A.G., Bogdanov A.N., Anuchin A.S. Switched reluctance motor flux linkage characteristic: experimental approach. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 858–865 (in Russian). doi: 10.17586/2226-1494-2024-24-5-858-865

### Введение

Одной из основных проблем вентильно-индукторных двигателей (ВИД) является возникновение пульсаций момента [1]. Для уменьшения пульсаций момента применяют методики: управление с прогнозирующей моделью с непрерывным управляющим воздействием [2, 3]; с конечным набором управляющих воздействий [4–6], где управление основывается на использовании данных из предварительно рассчитанных поисковых таблиц (Look-up Table) [7]. Упомянутые методики используют карту намагничивания как функцию углового положения ротора, тока и потокосцепления.

Для идентификации карты намагничивания пользуются двумя методами, разделенными по принципу работы: онлайн- и оффлайн-методики.

Оффлайн-методики [8–10] позволяют получить карту намагничивания ВИД с помощью специальной испытательной оснастки, при этом характеристика строится на полном обороте ротора во всем диапазоне изменения тока. Среди оффлайн-методик используются: прямой способ измерения потокосцепления якоря посредством электродвигущей силы самоиндукции дополнительной катушки индуктивности [10]; методика построения карты намагничивания с искусственно заторможенным ротором ВИД [8] и методика расчета карты по известной моментной характеристике двигателя [9].

При онлайн-методике [11] параметры карты намагничивания двигателя определяются во время

обычного режима работы ВИД, при этом полученные данные соответствуют мгновенным значениям токов фаз и положения ротора, при котором происходило измерение.

### Обзор методик

Подход, описанный в работе [10], основан на измерении изменения магнитного потока в проверяющей катушке при изменении тока от одного значения к другому. Однако данное решение применяется для машин большой мощности и требует сложной, крупногабаритной оснастки, что ограничивает ее применение. Работа методики, описанная в [8], основывается на блокировке положения ротора в любом желаемом положении с последующей подачей напряжения на обмотку и измерение параметров. Преимущество данной методики заключается в отсутствии необходимости управления ВИД во время измерений. К недостаткам относится наличие дополнительного оборудования для блокировки ротора и постоянная переналадка для каждого положения. В работе [9] представлен способ косвенного измерения через известную моментную характеристику. В отличии от других подходов, данный способ не требует сложной оснастки и базируется на измерении момента двигателя с помощь динамометра. Измерения производятся в нескольких угловых положениях от рассогласованного к согласованному, а поскольку картина распределения момента симметрич-

на относительно центральной оси полюса статора, то полученные измерения составят половину поверхности распределения.

В онлайн-методиках [11] параметры карты намагничивания двигателя определяются во время обычного режима работы ВИД, при этом полученные данные соответствуют мгновенным значениям токов фаз и положения ротора, при котором происходило измерение. Онлайн-идентификация параметров ВИД ограничивается рабочей областью и не дает возможности получить полную карту намагничивания [12].

Известна онлайн-методика построения карты намагничивания ВИД [13], включающая в себя оценку сопротивления обмотки, основанная на использовании виртуального измерительного прибора на базе цифрового сигнального процессора (например, dSPACE DS1003/DS1004 Alphacombo с платой DS2201 Multi-I/O, 20 12-битных аналого-цифровых преобразователей (АЦП), 8 12-битных цифро-аналоговых преобразователей (ЦАП), осуществляющего расчет потокосцепления по измеренным данным тока с шагом 0,01 А и угла поворота ротора. Недостатком данного решения является использование сложного и дорогостоящего оборудования для обработки данных. В работе [14] приведен способ вычисления потокосцепления по данным измерений фазового тока и напряжения с учетом максимального тока двигателя, а в [15] — метод нечеткой логики для построения карты намагничивания на основе измеренных токов и напряжений фаз в зависимости от контрольных точек угла поворота ротора. К недостаткам метода [15] относится зависимость от правильного выбора правил использования нечеткой логики и высокие требования к знаниям и опыту для настройки системы.

Идентификация карты намагничивания ВИД критически важна как для проектирования системы управле-

ния, так и для оценки потерь в силовых ключах [16] при работе ВИД, в частности, в системах электротранспорта [17], где ВИД работает в области поддержания постоянного момента или постоянной мощности. Нагрев ВИД в процессе работы приводит к изменению [18] кривой намагничивания, что также необходимо учитывать при проектировании системы управления, что нереализуемо при отсутствии идентифицированной первоначальной кривой. При проектировании систем с косвенным определением положения ротора — бездатчиковых систем [19], также критически важным является наличие корректной зависимости потокосцепления от тока и угла поворота ротора [20].

Целью работы является разработка методики построения карты намагничивания ВИД с использованием экспериментального стенда и программного обеспечения для обработки полученных данных. Результаты исследования позволят получить полное представление о распределении потокосцепления в зависимости от тока и положения ротора, что является необходимым этапом для последующего проектирования системы.

### Описание методики

В настоящей работе применен экспериментальный подход построения карты намагничивания, при которой требуется искусственное торможение ротора. На рис. 1 представлена функциональная схема экспериментального стенда.

Принцип работы стенда заключается в следующем: ротор ВИД блокируется механически в любом желаемом положении. Положение ротора может измеряться датчиком положения. С помощью полупроводникового преобразователя на базе биполярных силовых транзисторов с изолированным затвором (Insulated Gate Bipolar Transistor) или IGBT-транзисторов осущест-

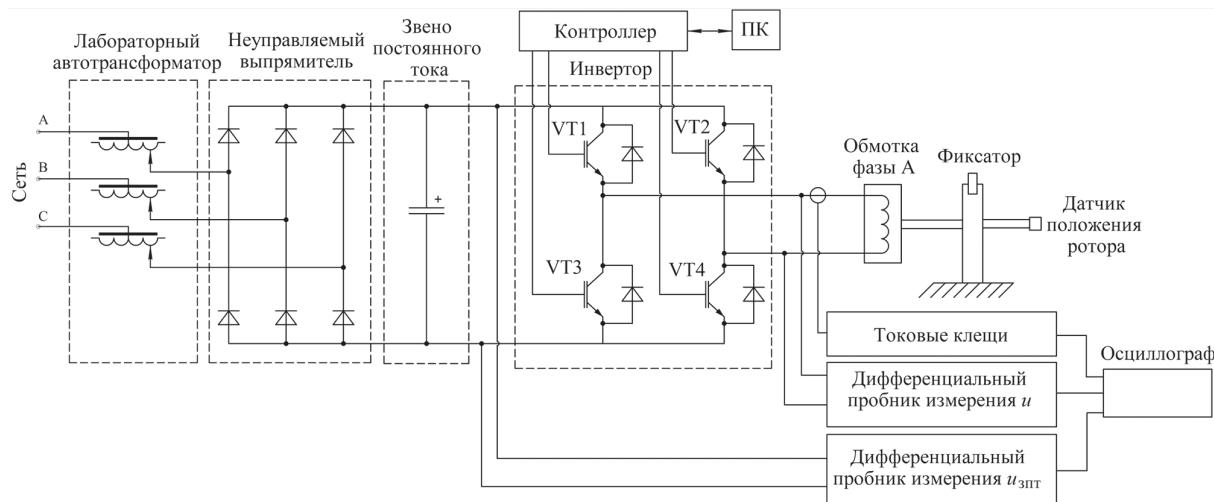


Рис. 1. Функциональная схема экспериментального стенда.

A, B, C — фазы сети, VT1–VT4 — транзисторные ключи, ПК — персональный компьютер,  $u$  — напряжение в измеряемой фазе,  $u_{зпт}$  — напряжение звена постоянного тока

Fig. 1. Functional diagram of the experimental stand

A, B, C — phases of electrical network, VT1–VT4 — transistor switches, ПК — personal computer,  $u$  — voltage in measured phase,  $u_{зпт}$  — voltage of the DC link

вляется периодическая подача напряжения на прове-  
ряемую обмотку фазы. Фазный ток и напряжение из-  
меряются с помощью соответствующих датчиков. Для  
построения карты намагничивания требуется измерить  
сопротивление обмотки, построить кривые фазных на-  
пряженя и тока, а также рассчитать потокосцепление.  
Необходимо выполнить несколько экспериментов в  
различных положениях ротора.

### Описание эксперимента

В качестве исследуемой машины использован экспериментальный образец ВИД со следующими номи-  
нальными параметрами: мощность — 7,5 кВт; число  
фаз — 3; число зубцов статора/ротора — 6/4; напряже-  
ние на звене постоянного тока — 540 В; ток — 19,1 А;  
частота вращения — 3000 об/мин. Стенд состоит из  
источника питания, исследуемого двигателя и системы  
измерения. В качестве источника питания применен ла-  
бораторный автотрансформатор (ЛАТР) с напряжением  
540 В, от которого напряжение подается на неуправляемый  
выпрямитель и далее со звена постоянного тока на инвертор. Управляющий контроллер подает сигнал  
широко-импульсной модуляции (ШИМ) на транзи-  
сторы со скважностью 1. На контроллере установлена  
защита по превышению тока. Такая схема позволяет  
подать скачкообразное напряжение на обмотку двига-  
теля. Показания тока снимаются с помощью токового  
пробника.

С целью предотвращения прокручивания ротора и  
его надежной фиксации в определенном положении

предусмотрена специальная механическая оснастка. На  
валу ротора установлен градуированный диск, закре-  
пленный на алюминиевой балке. Конец балки жестко  
закреплен пружинными зажимами. Общая схема стенда  
в сборе представлена на рис. 2.

Измерение тока в обмотке произведено с помощью  
токового пробника для осциллографа Pintek PA-677.  
Измерение напряжения выполнено с помощью вы-  
соковольтного дифференциального пробника Micsig  
DP10007. Характеристики токового и высоковольтного  
дифференциального пробников представлены в табл. 1.

Показания пробников считаются и выводятся  
сразу на осциллограф АКИП-4126/4А-Х. Снятые по-  
казания переводятся на съемный носитель и обрабаты-  
ваются программными средствами.

Эксперимент проводился по следующей методике.  
Перед началом эксперимента к фазе двигателя под-  
ключают токовый пробник, а к звену постоянного тока и  
выходу инвертора — дифференциальный пробник.  
Контроллер настраивают на отключение системы при  
достижении ограничения по току в 19 А. Затем врача-  
ют рукоятку ЛАТР до достижения напряжения 540 В  
на звене постоянного тока. На фазу двигателя через  
неуправляемый выпрямитель и инвертор подают скачи-  
кообразное напряжение и проверяют, что двигатель  
занимает согласованное положение. Значения тока и на-  
пряженя фиксируются осциллографом и сохраняются  
на электронный носитель. Далее ротор отклоняют на 6°  
по шкале и жестко фиксируют. Эксперимент повторяют  
с подачи скачкообразного напряжения, снимая показа-  
ния в 17 положениях. После проведения экспериментов



Рис. 2. Фотография экспериментального стенда: 1 — фиксирующая оснастка; 2 — вентильно-индукторный двигатель;  
3 — неуправляемый выпрямитель, инвертор и контроллер; 4 — токовые клещи; 5 — токовые и дифференциальные  
пробники; 6 — осциллограф

Fig. 2. Photo of the experimental equipment. 1 — fixing tool; 2 — switched reluctance motor; 3 — uncontrolled rectifier, inverter  
and controller; 4 — current clamps; 5 — current and differential probes; 6 — oscilloscope

Таблица 1. Параметры датчика тока и высоковольтного дифференциального пробника

Table 1. Current sensor parameters and the high-voltage differential probe

Параметр	Значение	
Токовый пробник		
Максимальный ток (DC), А	от -70 до +70	
Максимальная рабочее напряжение, В	600	
Частотный диапазон (DC), МГц	1	
Точность в диапазоне 500 мВ/А (20 мА-14 А)	$\pm(3\%+20\text{ mA})$	
Точность в диапазоне 50 мВ/А (200 мА-100 А)	$\pm(4\%+200\text{ mA})$	
Высоковольтный дифференциальный пробник		
Полоса пропускания, МГц	100	
Коэффициент деления	1/10	1/100
Максимальное дифференциальное напряжение, В	70	700
Максимальное входное напряжение, В	600 (CAT II) 1000 (CAT I)	
Точность, %	$\pm 2$	

Примечание: САТ I — приборы, предназначены для работы с источниками напряжения, которые не подключены непосредственно к сети электроснабжения; САТ II — приборы, которые могут работать с цепями, подключенными к низковольтной электрической сети через стандартные розетки, такие как бытовая техника.

и обработки результатов были получены графики токов и напряжений для каждого положения ротора, пример которых для согласованного положения показан на рис. 3.

На графиках показано напряжение  $u$  на обмотке двигателя в фазе А, фазный ток  $i$  и напряжение на звене постоянного тока  $u_{\text{зпт}}$ . В начале измерения открываетсяся ключ VT1, VT4, в течение всего эксперимента ключи остаются открытыми и закрываются только в конце измерения. Ввиду того, что в ходе эксперимента отсутствует ШИМ-модуляция ключей, измеренное напряжение на обмотке равно напряжению на звене постоянного тока за вычетом падения напряжения (приблизительно 2 В) на ключах VT1 и VT4. Данный опыт эквивалентен опыту короткого замыкания, что обуславливает пропадку напряжения на звене постоянного тока в 15 В к концу измерения.

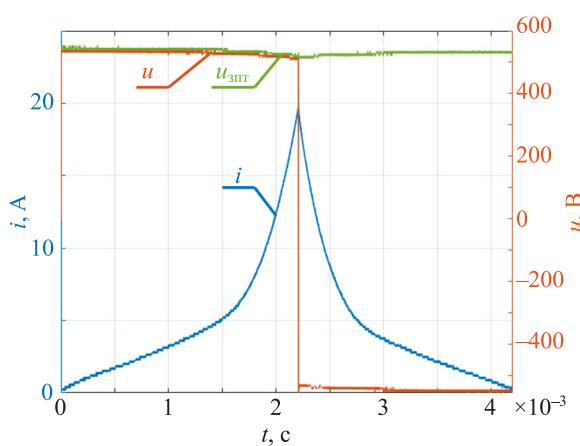


Рис. 3. Графики тока и напряжения в согласованном положении ротора

Fig. 3. Current and voltage graphs in the matched rotor position

## Обработка результатов

Полученные графики токов и значений напряжений позволяют построить кривые потокосцепления для каждого углового положения по следующей формуле:

$$\psi(t) = \int_0^t (u(t) - Ri(t)) dt + \psi(0), \quad (1)$$

где  $\psi(0)$  — начальное значение потокосцепления ( $t = 0$ );  $u(t)$  — напряжение на фазе;  $i(t)$  — ток в фазе ВИД;  $R$  — сопротивление фазной обмотки.

Сопротивление фазной обмотки  $R$  было измерено и составляет 1,6 Ом. По формуле (1) выполнено интегрирование кривой тока для каждого положения с шагом 1 А. Проинтегрировав кривые тока и получив значения потокосцепления, можно построить расчетные характеристики (рис. 4).

Для получения полной карты намагничивания осуществлялись измерения во всех 17 положениях. В результате была получена поверхность, изображенная на рис. 5.

Моделирование карты и построение графиков проводились с использованием программного пакета MATLAB. Алгоритм построения полной карты намагничивания включал следующие этапы. Данные, полученные в ходе расчетов, были разделены по трем параметрам: сила тока, потокосцепление и угол. Эти данные дополнены восемью точками в сторону уменьшения угла  $\theta$  (от 111 до 63°) и девятью точками в сторону увеличения угла (от 111 до 159°). Выполнено построение графика по дополненным точкам, при этом количество точек по углу и по току было установлено на уровне 50 значений. Промежуточные значения для всей карты намагничивания определены методом интерполяции. В результате на основе расширенного набора данных была синтезирована поверхность намагничивания ВИД.

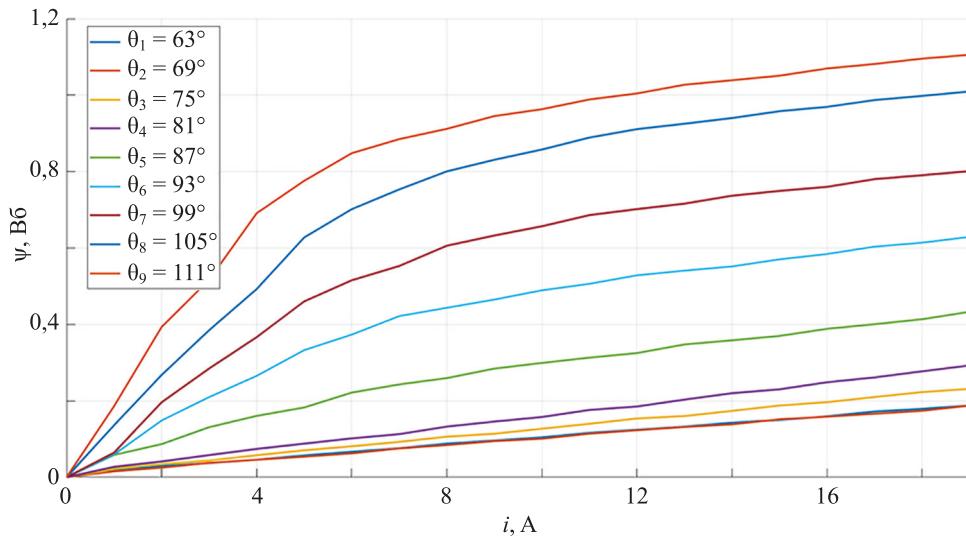
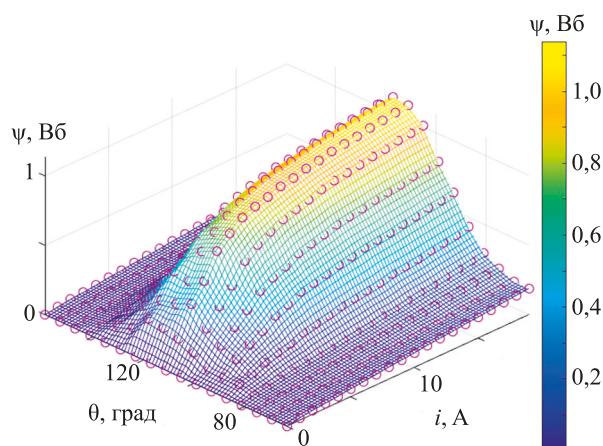
Рис. 4. График зависимости потокосцепления от тока, где  $\theta$  — угол положения ротораFig. 4. Graph of the dependence of flux-current, where  $\theta$  is the angle of the rotor position

Рис. 5. Полная карта намагничивания

Fig. 5. Full magnetization map

### Заключение

Разработан необходимый и достаточный для построения карты намагничивания вентильно-индукторного двигателя экспериментальный подход — от подготовки экспериментального стенда до способов обработки полученных результатов. Для обработки полученных данных разработана программа для расчета потокосцепления и построения карты намагничивания. Полученные методики были верифицированы на вентильно-индукторном двигателе конфигурации 6/4 мощностью 7,5 кВт и позволили получить карту намагничивания для диапазона положений от 63 до 159° при согласованном положении в 111°. Полученная карта дает полное представление о распределении потокосцепления в зависимости от тока и положения ротора вентильно-индукторного двигателя, что в дальнейшем может быть применено при проектировании системы управления.

### Литература

1. Krasovsky A. Simulation and analysis of improved direct torque control of switched reluctance machine // Indonesian Journal of Electrical Engineering and Computer Science. 2020. V. 18. N. 1. P. 251–260. <https://doi.org/10.11591/ijeecs.v18.i1.pp251-260>
2. Anuchin A., Demidova G.L., Hao C., Zharkov A., Bogdanov A., Šmidl V. Continuous control set model predictive control of a switch reluctance drive using lookup tables // Energies. 2020. V. 13. N. 13. P. 3317. <https://doi.org/10.3390/en13133317>
3. Fang G., Ye J., Xiao D., Xia Z., Emadi A. Low-Ripple continuous control set model predictive torque control for switched reluctance machines based on equivalent linear SRM model // IEEE Transactions on Industrial Electronics. 2022. V. 69. N. 12. P. 12480–12495. <https://doi.org/10.1109/TIE.2021.3130344>
4. Rodriguez J., Kazmierkowski M.P., Espinoza J.R., Zanchetta P., Abu-Rub H., Young H.A., Rojas C.A. State of the art of finite control set model predictive control in power electronics // IEEE Transactions on Industrial Informatics. 2013. V. 9. N. 2. P. 1003–1016. <https://doi.org/10.1109/TII.2012.2221469>
5. Rodriguez J., Garcia C., Mora A., Flores-Bahamonde F., Acuna P., Novak M., Zhang Y., Tarisciotti L., Davari S.A., Zhang Z., Wang F.,

### References

1. Krasovsky A. Simulation and analysis of improved direct torque control of switched reluctance machine. *Indonesian Journal of Electrical Engineering and Computer Science*, 2020, vol. 18, no. 1, pp. 251–260. <https://doi.org/10.11591/ijeecs.v18.i1.pp251-260>
2. Anuchin A., Demidova G.L., Hao C., Zharkov A., Bogdanov A., Šmidl V. Continuous control set model predictive control of a switch reluctance drive using lookup tables. *Energies*, 2020, vol. 13, no. 13, pp. 3317. <https://doi.org/10.3390/en13133317>
3. Fang G., Ye J., Xiao D., Xia Z., Emadi A. Low-Ripple continuous control set model predictive torque control for switched reluctance machines based on equivalent linear SRM model. *IEEE Transactions on Industrial Electronics*, 2022, vol. 69, no. 12, pp. 12480–12495. <https://doi.org/10.1109/TIE.2021.3130344>
4. Rodriguez J., Kazmierkowski M.P., Espinoza J.R., Zanchetta P., Abu-Rub H., Young H.A., Rojas C.A. State of the art of finite control set model predictive control in power electronics. *IEEE Transactions on Industrial Informatics*, 2013, vol. 9, no. 2, pp. 1003–1016. <https://doi.org/10.1109/TII.2012.2221469>
5. Rodriguez J., Garcia C., Mora A., Flores-Bahamonde F., Acuna P., Novak M., Zhang Y., Tarisciotti L., Davari S.A., Zhang Z., Wang F.,

- Norambuena M., Dragicevic T., Blaabjerg F., Geyer T., Kennel R., Khaburi D.A., Abdelrahem M., Zhang Z., Mijatovic N., Aguilera R.P. Latest advances of model predictive control in electrical drives—Part I: Basic concepts and advanced strategies // *IEEE Transactions on Power Electronics*. 2022. V. 37. N 4. P. 3927–3942. <https://doi.org/10.1109/TPEL.2021.3121532>
6. Rodriguez J., Garcia C., Mora A., Davari S.A., Rodas J., Valencia D.F., Elmorsheyd M., Wang F., Zuo K., Tarisciotti L., Flores-Bahamonde F., Xu W., Zhang Z., Zhang Y., Norambuena M., Emadi A., Geyer T., Kennel R., Dragicevic T., Khaburi D.A., Zhang Z., Abdelrahem M., Mijatovic N. Latest Advances of model predictive control in electrical drives—Part II: applications and benchmarking with classical control methods // *IEEE Transactions on Power Electronics*. 2022. V. 37. N 5. P. 5047–5061. <https://doi.org/10.1109/TPEL.2021.3121589>
  7. Memon A., Shaikh M.M., Bukhari S.S.H., Ro J.-S. Look-up data tables-based modeling of switched reluctance machine and experimental validation of the static torque with statistical analysis // *Journal of Magnetics*. 2020. V. 25. N 2. P. 233–244. <https://doi.org/10.4283/JMAG.2020.25.2.233>
  8. Chancharoensook P., Rahman M.F. Magnetization and static torque characterization of a four-phase switched reluctance motor: experimental investigations // Proc. of the 4<sup>th</sup> IEEE International Conference on Power Electronics and Drive Systems. IEEE PEDS 2001 – Indonesia. Proceedings (Cat. No.01TH8594). V. 2. 2001. P. 456–460. <https://doi.org/10.1109/PEDS.2001.975359>
  9. Cossar C., Miller T.J.E. Electromagnetic testing of switched reluctance motors // Proc. of International Conference on Electrical Machines. 1992. P. 470–474.
  10. Prescott J.C., El-Kharashi A.K. A method of measuring self-inductances applicable to large electrical machines // Proceedings of the IEE Part A: Power Engineering. 1959. V. 106. N 26. P. 169–173. <https://doi.org/10.1049/pi-a.1959.0070>
  11. Cossar C., Popescu M., Miller T., McGilp M. On-line phase measurements in switched reluctance motor drives // Proc. of the European Conference on Power Electronics and Applications. 2007. P. 1–8. <https://doi.org/10.1109/epe.2007.4417358>
  12. Anuchin A., Bogdanov A., Demidova G., Stolyarov E., Surnin D., Vagapov Y. Online magnetization surface identification for a switched reluctance motor // Proc. of the 55<sup>th</sup> International Universities Power Engineering Conference (UPEC). 2020. P. 1–5. <https://doi.org/10.1109/UPEC49904.2020.9209832>
  13. Cheok A.D., Wang Z. Flux linkage measurement method for switched reluctance motors and inductor/transformers using a real-time DSP system // *International Journal of Electronics*. 2002. V. 89. N 8. P. 625–644. <https://doi.org/10.1080/0020721021000057571>
  14. Switched reluctance motor flux linkage characteristic measurement method. Patent CN201010018146A. 2010.
  15. Liu J., Wang G., Sun L., Liu D., Fan Y. A novel method to obtain the flux-linkage characteristics of switched reluctance motors // *IEEE Transactions on Magnetics*. 2021. V. 57. N 11. P. 8205011. <https://doi.org/10.1109/TMAG.2021.3111521>
  16. Xu Y., Gu J., Chen H., Chen Z., Pu Y. Power loss calculation for the power converter in switched reluctance motor drive // Proc. of the IEEE International Conference on Information and Automation (ICIA). 2014. P. 19–24. <https://doi.org/10.1109/ICInFA.2014.6932619>
  17. He C., Hao C., Qianlong W., Shaohui X., Shunyao Y. Design and control of switched reluctance motor drive for electric vehicles // Proc. of the 14<sup>th</sup> International Conference on Control, Automation, Robotics and Vision (ICARCV). 2016. P. 1–6. <https://doi.org/10.1109/ICARCV.2016.7838783>
  18. Chen H., Wang K., Yan W., Orabia M., Parspour N. Temperature analysis of switched reluctance motor based on equivalent heat circuit method // *IEEE Transactions on Applied Superconductivity*. 2021. V. 31. N 8. P. 0604104. <https://doi.org/10.1109/TASC.2021.3117753>
  19. Sarr A., Bahri I., Diallo D., Berthelot E. Sensorless control of Switched Reluctance Machine // Proc. of the IECON 2016 — 42<sup>nd</sup> Annual Conference of the IEEE Industrial Electronics Society. 2016. P. 6693–6698. <https://doi.org/10.1109/IECON.2016.7793584>
  20. Anuchin A., Shpak D., Kotelnikova A., Dmitriev A., Bogdanov A., Demidova G. Encoderless rotor position estimation of a switched reluctance drive operated under model predictive control // Proc. of the 61<sup>th</sup> International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON). 2020. P. 1–6. <https://doi.org/10.1109/RTUCON51174.2020.9316621>
  - Norambuena M., Dragicevic T., Blaabjerg F., Geyer T., Kennel R., Khaburi D.A., Abdelrahem M., Zhang Z., Mijatovic N., Aguilera R.P. Latest advances of model predictive control in electrical drives—Part I: Basic concepts and advanced strategies // *IEEE Transactions on Power Electronics*, 2022, vol. 37, no. 4, pp. 3927–3942. <https://doi.org/10.1109/TPEL.2021.3121532>
  6. Rodriguez J., Garcia C., Mora A., Davari S.A., Rodas J., Valencia D.F., Elmorsheyd M., Wang F., Zuo K., Tarisciotti L., Flores-Bahamonde F., Xu W., Zhang Z., Zhang Y., Norambuena M., Emadi A., Geyer T., Kennel R., Dragicevic T., Khaburi D.A., Zhang Z., Abdelrahem M., Mijatovic N. Latest Advances of model predictive control in electrical drives—Part II: applications and benchmarking with classical control methods // *IEEE Transactions on Power Electronics*, 2022, vol. 37, no. 5, pp. 5047–5061. <https://doi.org/10.1109/TPEL.2021.3121589>
  7. Memon A., Shaikh M.M., Bukhari S.S.H., Ro J.-S. Look-up data tables-based modeling of switched reluctance machine and experimental validation of the static torque with statistical analysis. *Journal of Magnetics*, 2020, vol. 25, no. 2, pp. 233–244. <https://doi.org/10.4283/JMAG.2020.25.2.233>
  8. Chancharoensook P., Rahman M.F. Magnetization and static torque characterization of a four-phase switched reluctance motor: experimental investigations. *Proc. of the 4<sup>th</sup> IEEE International Conference on Power Electronics and Drive Systems. IEEE PEDS 2001 – Indonesia. Proceedings (Cat. No.01TH8594)*. V. 2, 2001, pp. 456–460. <https://doi.org/10.1109/PEDS.2001.975359>
  9. Cossar C., Miller T.J.E. Electromagnetic testing of switched reluctance motors. *Proc. of International Conference on Electrical Machines*, 1992, pp. 470–474.
  10. Prescott J.C., El-Kharashi A.K. A method of measuring self-inductances applicable to large electrical machines. *Proceedings of the IEE Part A: Power Engineering*, 1959, vol. 106, no. 26, pp. 169–173. <https://doi.org/10.1049/pi-a.1959.0070>
  11. Cossar C., Popescu M., Miller T., McGilp M. On-line phase measurements in switched reluctance motor drives. *Proc. of the European Conference on Power Electronics and Applications*, 2007, pp. 1–8. <https://doi.org/10.1109/epe.2007.4417358>
  12. Anuchin A., Bogdanov A., Demidova G., Stolyarov E., Surnin D., Vagapov Y. Online magnetization surface identification for a switched reluctance motor. *Proc. of the 55<sup>th</sup> International Universities Power Engineering Conference (UPEC)*, 2020, pp. 1–5. <https://doi.org/10.1109/UPEC49904.2020.9209832>
  13. Cheok A.D., Wang Z. Flux linkage measurement method for switched reluctance motors and inductor/transformers using a real-time DSP system. *International Journal of Electronics*, 2002, vol. 89, no. 8, pp. 625–644. <https://doi.org/10.1080/0020721021000057571>
  14. Switched reluctance motor flux linkage characteristic measurement method. Patent CN201010018146A. 2010.
  15. Liu J., Wang G., Sun L., Liu D., Fan Y. A novel method to obtain the flux-linkage characteristics of switched reluctance motors. *IEEE Transactions on Magnetics*, 2021, vol. 57, no. 11, pp. 8205011. <https://doi.org/10.1109/TMAG.2021.3111521>
  16. Xu Y., Gu J., Chen Z., Pu Y. Power loss calculation for the power converter in switched reluctance motor drive. *Proc. of the IEEE International Conference on Information and Automation (ICIA)*, 2014, pp. 19–24. <https://doi.org/10.1109/ICInFA.2014.6932619>
  17. He C., Hao C., Qianlong W., Shaohui X., Shunyao Y. Design and control of switched reluctance motor drive for electric vehicles. *Proc. of the 14<sup>th</sup> International Conference on Control, Automation, Robotics and Vision (ICARCV)*, 2016, pp. 1–6. <https://doi.org/10.1109/ICARCV.2016.7838783>
  18. Chen H., Wang K., Yan W., Orabia M., Parspour N. Temperature analysis of switched reluctance motor based on equivalent heat circuit method. *IEEE Transactions on Applied Superconductivity*, 2021, vol. 31, no. 8, pp. 0604104. <https://doi.org/10.1109/TASC.2021.3117753>
  19. Sarr A., Bahri I., Diallo D., Berthelot E. Sensorless control of Switched Reluctance Machine. *Proc. of the IECON 2016 — 42<sup>nd</sup> Annual Conference of the IEEE Industrial Electronics Society*, 2016, pp. 6693–6698. <https://doi.org/10.1109/IECON.2016.7793584>
  20. Anuchin A., Shpak D., Kotelnikova A., Dmitriev A., Bogdanov A., Demidova G. Encoderless rotor position estimation of a switched reluctance drive operated under model predictive control. *Proc. of the 61<sup>th</sup> International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON)*, 2020, pp. 1–6. <https://doi.org/10.1109/RTUCON51174.2020.9316621>

## Авторы

**Яременко Андрей Михайлович** — аспирант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0009-0007-7220-3957>, amyaremenko@itmo.ru

**Демидова Галина Львовна** — кандидат технических наук, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 56974083200](https://orcid.org/0000-0003-2786-715X), <https://orcid.org/0000-0003-2786-715X>, demidova@itmo.ru

**Сорокина Алла Алексеевна** — инженер, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0009-0001-7466-4673>, 265957@niuitmo.ru

**Маматов Александр Геннадьевич** — кандидат технических наук, ассистент, руководитель группы, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57191075351](https://orcid.org/0000-0002-1887-3059), <https://orcid.org/0000-0002-1887-3059>, amamatov@itmo.ru

**Богданов Андрей Николаевич** — аспирант, Московский энергетический институт, Москва, 111250, Российская Федерация, <https://orcid.org/0009-0007-3858-5859>, anbogdanov@itmo.ru

**Анучин Алексей Сергеевич** — доктор технических наук, профессор, заведующий кафедрой, Московский энергетический институт, Москва, 111250, Российская Федерация, [sc 56168843400](https://orcid.org/0000-0002-1019-756X), <https://orcid.org/0000-0002-1019-756X>, anuchin.alecksey@itmo.ru

## Authors

**Andrey M. Yaremenko** — PhD Student, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0009-0007-7220-3957>, amyaremenko@itmo.ru

**Galina L. Demidova** — PhD, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 56974083200](https://orcid.org/0000-0003-2786-715X), <https://orcid.org/0000-0003-2786-715X>, demidova@itmo.ru

**Alla A. Sorokina** — Engineer, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0009-0001-7466-4673>, 265957@niuitmo.ru

**Aleksandr G. Mamatov** — PhD, Assistant, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57191075351](https://orcid.org/57191075351), <https://orcid.org/0000-0002-1887-3059>, amamatov@itmo.ru

**Andrey N. Bogdanov** — PhD Student, Moscow Power Engineering Institute, Moscow, 111250, Russian Federation, <https://orcid.org/0009-0007-3858-5859>, anbogdanov@itmo.ru

**Alecksey S. Anuchin** — D.Sc., Professor, Head of Department, Moscow Power Engineering Institute, Moscow, 111250, Russian Federation, [sc 56168843400](https://orcid.org/56168843400), <https://orcid.org/0000-0002-1019-756X>, anuchin.alecksey@itmo.ru

Статья поступила в редакцию 05.06.2024

Одобрена после рецензирования 27.08.2024

Принята к печати 28.09.2024

Received 05.06.2024

Approved after reviewing 27.08.2024

Accepted 28.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

## КРАТКИЕ СООБЩЕНИЯ

## BRIEF PAPERS

doi: 10.17586/2226-1494-2024-24-5-866-870  
 УДК 539.234

### Спектральная зависимость квантовой эффективности фотоэлектрохимического разложения воды нанопористыми слоями серебра

Александр Иванович Сидоров<sup>1</sup>, Алексей Викторович Нашекин<sup>2</sup>,  
 Николай Валентинович Никоноров<sup>3</sup>

<sup>1,3</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>1</sup> Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург, 197022, Российская Федерация

<sup>2</sup> Физико-технический институт им. А.Ф. Иоффе, Санкт-Петербург, 194021, Российская Федерация

<sup>1</sup> [sidorov@oi.ifmo.ru](mailto:sidorov@oi.ifmo.ru), <https://orcid.org/0000-0001-8730-4389>

<sup>2</sup> [nashchekin@mail.ioffe.ru](mailto:nashchekin@mail.ioffe.ru), <https://orcid.org/0000-0002-2542-7364>

<sup>3</sup> [nikonorov@oi.ifmo.ru](mailto:nikonorov@oi.ifmo.ru), <https://orcid.org/0000-0002-1341-067X>

#### Аннотация

Представлены результаты исследования спектральной зависимости квантовой эффективности фотокаталитического разложения воды. Определена связь спектра излучения с эффективностью фотокаталитического разложения воды на водород и кислород. С этой целью исследован электролит на основе нитрата натрия. Фотокатод содержал нанопористые слои серебра. Показано, что максимальная квантовая эффективность фотокаталитического разложения воды по спектру интегрально составляет 1,9 %, а с уменьшением длины волны излучения повышается. Полученные результаты могут быть использованы при разработке устройств солнечной энергетики, предназначенных для фотокаталитического разложения воды на водород и кислород.

#### Ключевые слова

фотокаталит, нанопористый слой, серебро, разложение воды

#### Благодарности

Работа выполнена при финансовой поддержке Российского научного фонда (проект № 20-19-00559).

Электронно-микроскопические исследования выполнены с использованием оборудования Федерального центра коллективного пользования «Материаловедение и диагностика в передовых технологиях», поддержанного Минобрнауки России.

**Ссылка для цитирования:** Сидоров А.И., Нашекин А.В., Никоноров Н.В. Спектральная зависимость квантовой эффективности фотоэлектрохимического разложения воды нанопористыми слоями серебра // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 5. С. 866–870.  
 doi: 10.17586/2226-1494-2024-24-5-866-870

### Spectral dependence of photoelectrochemical water splitting by silver nanoporous layers

Alexander I. Sidorov<sup>1</sup>, Aleksey V. Nashchekin<sup>2</sup>, Nikolay V. Nikonorov<sup>3</sup>

<sup>1,3</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>1</sup> Saint Petersburg State Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation

<sup>2</sup> Ioffe Institute, Saint Petersburg, 194021, Russian Federation

<sup>1</sup> [sidorov@oi.ifmo.ru](mailto:sidorov@oi.ifmo.ru), [http://orcid.org/0000-0001-8730-4389](https://orcid.org/0000-0001-8730-4389)

<sup>2</sup> [nashchekin@mail.ioffe.ru](mailto:nashchekin@mail.ioffe.ru), [http://orcid.org/0000-0002-2542-7364](https://orcid.org/0000-0002-2542-7364)

<sup>3</sup> [nikonorov@oi.ifmo.ru](mailto:nikonorov@oi.ifmo.ru), [http://orcid.org/0000-0002-1341-067X](https://orcid.org/0000-0002-1341-067X)

#### Abstract

The article presents the results of the spectral dependence study of the quantum efficiency of photocatalytic water decomposition. The relationship between the radiation spectrum and the efficiency of photocatalytic water decomposition

© Сидоров А.И., Нашекин А.В., Никоноров Н.В., 2024

into hydrogen and oxygen is determined. For this purpose, an electrolyte based on sodium nitrate is studied. The photocathode contained nanoporous silver layers. It is shown that the maximum quantum efficiency of photocatalytic water decomposition by spectrum integrally amounts to 1.9 %, and increases with decreasing radiation wavelength. The obtained results can be used in the development of solar energy devices designed for photocatalytic water decomposition into hydrogen and oxygen.

#### Keywords

photocatalysis, nanoporous layer, silver, water splitting

#### Acknowledgements

This work was financially supported by the Russian Science Foundation (Project No. 20-19-00559).

SEM characterization were performed using equipment owned by the Federal Joint Research Center “Material Science and Characterization in Advanced Technology” with financial support by the Ministry of Education and Science of the Russian Federation.

**For citation:** Sidorov A.I., Nashchekin A.V., Nikonorov N.V. Spectral dependence of photoelectrochemical water splitting by silver nanoporous layers. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 5, pp. 866–870 (in Russian). doi: 10.17586/2226-1494-24-5-866-870

Фотокаталитическое (ФК) разложение воды на водород и кислород является одним из направлений развития возобновляемых источников энергии. В ряде экспериментальных и теоретических работ показаны возможности эффективного разложения воды в микро- и нанопористых (НП) слоях металлов и полупроводников [1–6]. Увеличение эмиссии фотоэлектронов может быть достигнуто в металлическихnanoструктурах за счет эффектов, возникающих в металле при возбуждении поверхностных плазмонов [7, 8].

В экспериментах по фотоэлектрохимическому разложению воды в основном используются лабораторные источники света [9–12]. Однако для практических применений важно изучение влияния спектра излучения на эффективность ФК разложения воды. При ФК разложении природной воды спектр излучения Солнца может меняться, в зависимости от географических факторов, погодных условий и времени суток. Исходя из этого, важной задачей является изучение спектральной зависимости эффективности ФК разложения воды.

Цели настоящей работы — синтез НП слоев на основе серебра и исследование внутренней квантовой эффективности разложения воды фотоэлектрохимическим методом в зависимости от спектра излучения.

В качестве подложек для НП слоев из серебра использовались полированные пластины из меди. Подложки имели размеры  $10 \times 10 \text{ мм}^2$  и толщину 0,5 мм. Для синтеза НП слоев из серебра применены химические реакции замещения [13]. Данный простой и технологичный метод синтеза позволяет изготавливать фотокатоды большой площади. Для синтеза НП слоя из серебра подложки из меди погружались в водный раствор азотнокислого серебра (3,75 вес.%). Продолжительность реакции составляла 3 с. Синтез проводился при комнатной температуре 20 °C.

После проведения реакций образцы промывались дистиллированной водой и высушивались. Структура и морфология НП слоев изучались с помощью сканирующего электронного микроскопа JSM 7001 F (JEOL).

Для фотоэлектрохимического разложения воды образцы помещались в ячейку, заполненную электролитом, и освещались через окно из кварцевого стекла. В качестве электролита использовался водный раствор нитрата натрия (6 вес.%). В качестве широкополосного источника излучения для интегральных по спектру

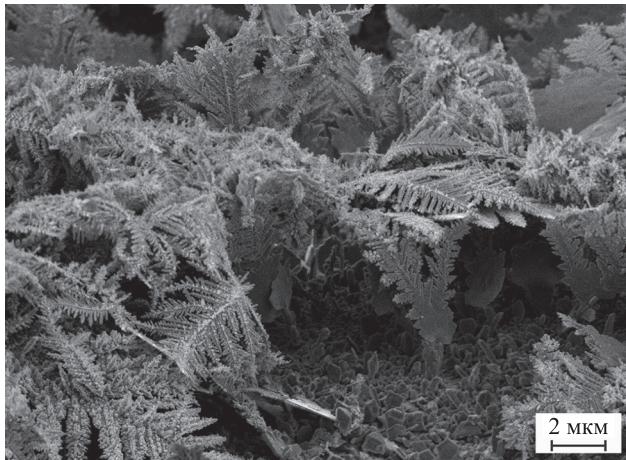
измерений использовался осветитель Novacure 2100 с ртутной лампой мощностью 3 Вт и спектральным интервалом излучения 250–500 нм. Для измерений на фиксированной длине волны применялись калиброванные полупроводниковые светодиоды с длинами волн 365, 450, 532 и 650 нм. Выбор источников излучения обусловлен тем, что они являются узкополосными. Кроме того, они позволяют проводить измерения от ультрафиолетового диапазона до красной области спектра. Измерения проводились при температуре 20 °C. Предварительные эксперименты, выполненные для длин волн излучения 450 нм и 650 нм, показали, что изменение плотности мощности в интервале 0,03–0,20 Вт/см<sup>2</sup> не влияет на квантовую эффективность ФК разложения воды. На ФК ячейку подавалось постоянное напряжение  $U = 0,5\text{--}5,0$  В через балластный резистор 1 кОм. Предварительные эксперименты показали, что при больших напряжениях в ФК ячейке начинаются процессы электролиза. Это приводит к изменению характеристик электродов, и их деградации. Внутренняя квантовая эффективность фотокатализа  $\eta$  определялась по формуле [14]:

$$\eta = \frac{N_e}{N_p} = \frac{I_p \hbar \omega}{P_{ab} e},$$

где  $N_e$  и  $N_p$  — количество фотоэлектронов и поглощенных фотонов;  $I_p$  — фототок;  $P_{ab}$  — поглощенная энергия;  $\omega$  — частота излучения;  $e$  — заряд электрона,  $\hbar$  — постоянная Планка.

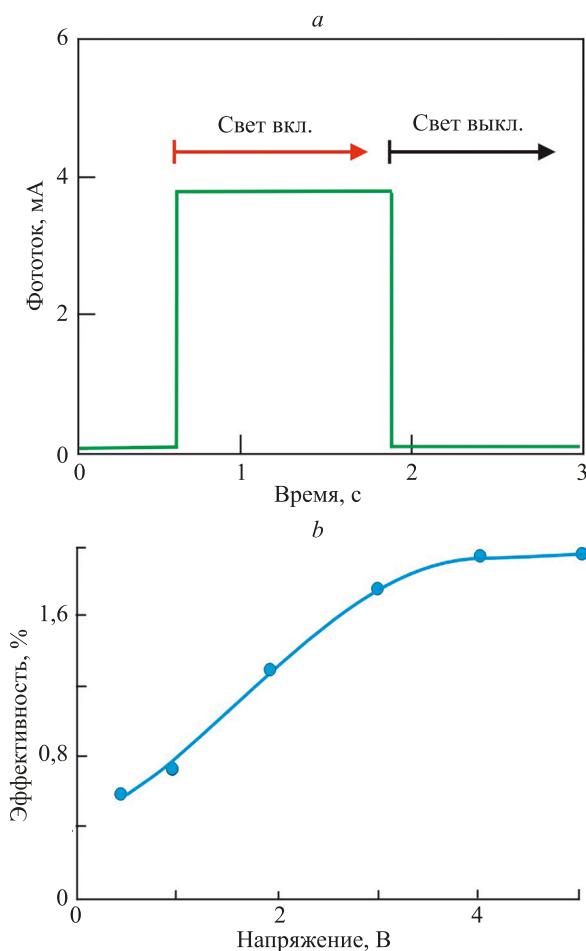
На рис. 1 показано изображение НП слоя серебра, полученное с помощью сканирующего электронного микроскопа, после проведения реакции замещения. НП слои из серебра состоят из ветвящихся фрактальных микроструктур длиной до 3 мкм. На концах ветвей расположены серебряные иглы длиной до 25 нм. За счет формирования такого НП слоя происходит увеличение эффективной площади фотокатода относительно площади подложки более чем в  $10^4$  раз.

При помещении фотокатода из НП серебра в ФК ячейку, заполненную электролитом, и подаче светового потока на фотокатод в цепи возникает фототок (рис. 2, a). Это указывает наявление фотоэлектрохимической реакции с разложением воды на водород и кислород. Интегральная по спектру зависимость кван-



*Rис. 1.* Изображение нанопористого слоя из серебра, полученного методом реакции замещения. Изображение получено с помощью сканирующего электронного микроскопа

*Fig. 1.* Image of silver NP layer, obtained by substitution reaction method. Image was obtained by scanning electron microscope



*Рис. 2.* Осциллографмограмма фототока после включения и выключения света (а); интегральная по спектру зависимость квантовой эффективности разложения воды от напряжения (б)

*Fig. 2.* Oscillogram of photocurrent after the light switching on and off (a); Integral spectrum dependence of quantum efficiency of water splitting on the voltage (b)

товой эффективности разложения воды от напряжения на ячейке показана на рис. 2, б. Из рисунка видно, что при увеличении напряжения возникает рост квантовой эффективности разложения воды. При  $U > 3$  В происходит насыщение зависимости. Максимальная квантовая эффективности разложения воды составляет 1,9 %. Для фиксированных длин волн зависимости квантового выхода от напряжения имеют аналогичный вид.

В таблице представлены относительные квантовые эффективности ФК разложения воды для разных длин волн. Из таблицы видно, что с уменьшением длины волны эффективность разложения воды увеличивается. Отметим, что даже в красной области спектра процесс фотокаталитика происходит, несмотря на малую энергию фотонов.

В случае объемного фотоэффекта электрон поглощает фотон и переходит в «горячее» состояние в объеме металла. Однако, когда он движется из объема металла к границе раздела сред, он теряет часть энергии за счет столкновений с термализованными электронами. В случае поверхностного фотоэффекта электрон поглощает энергию фотона на границе раздела сред, и у него есть возможность выйти из металла с малыми потерями энергии. Электрон после выхода в электролит способен восстанавливать ионы водорода. Очевидно, что у электронов, поглотивших фотон с большей энергией вероятность выхода за пределы металла больше. При малой энергии фотона, например, в красной области спектра, поверхностные плазмоны, которые возникают на металлических фрактальныхnanoструктурах, могут интерферировать между собой. Это приводит к появлению «горячих точек», в которых может происходить «разогрев» электронов. Это позволяет им выйти за пределы металла.

Экспериментально показано, что максимальная квантовая эффективность ФК разложения воды интегрально по спектру составляет 1,9 %, а с уменьшением длины волны излучения увеличивается. При этом ФК процесс происходит в красной области спектра за счет разогрева электронов при появлении «горячих точек» во фрактальных серебряных nanoструктурах. Полученные результаты могут быть использованы при разработке устройств солнечной энергетики, предназначенных для ФК разложения воды на водород и кислород.

*Таблица.* Влияние длины волны излучения ( $\lambda$ ) на относительную квантовую эффективность ( $\eta = \eta(\lambda)/\eta(\sum\eta(\lambda))$ ) фотокаталитического разложения воды.  $U = 1$  В

*Table.* Influence of radiation wavelength ( $\lambda$ ) on relative quantum efficiency ( $\eta = \eta(\lambda)/\eta(\sum\eta(\lambda))$ ) of photocatalytic water splitting.  $U = 1$  V

$\lambda$ , нм	Интенсивность излучения, $\text{Bt}/\text{cm}^2$	$\eta$
365	0,10	0,41
405	0,04	0,30
450	0,20	0,15
532	0,04	0,10
650	0,04	0,04

## Литература

1. Morales-Guio C.G., Tilley S.D., Vrubel H., Grätzel M., Hu X. Hydrogen evolution from a copper(I) oxide photocathode coated with an amorphous molybdenum sulphide catalyst // *Nature Communications*. 2014. V. 5. P. 3059. <https://doi.org/10.1038/ncomms4059>
2. Walter M.G., Warren E.L., McKone J.R., Boettcher S.W., Mi Q., Santori E.A., Lewis N.S. Solar water splitting cells // *Chemical Reviews*. 2010. V. 110. N 11. P. 6446–6478. <https://doi.org/10.1021/cr1002326>
3. Ben-Shahar Y., Scogognella F., Kriegel I., Moretti L., Cerullo G., Rabani E., Banin U. Optimal metal domain size for photocatalysis with hybrid semiconductor-metal nanorods // *Nature Communications*. 2016. V. 7. P. 10413. <https://doi.org/10.1038/ncomms10413>
4. Gan J., Lu X., Tong Y. Towards highly efficient photoanodes: boosting sunlight-driven semiconductor nanomaterials for water oxidation // *Nanoscale*. 2014. V. 6. N 13. P. 7142–7152. <https://doi.org/10.1039/c4nr01181c>
5. Koya A.N., Zhu X., Ohannesian N., Yanik A.A., Alabastri A., Zaccaria R.P., Krahne R., Shih R.K.W.-C., Garoli D. Nanoporous metals: From plasmonic properties to applications in enhanced spectroscopy and photocatalysis // *ACS Nano*. 2021. V. 15. N 4. P. 6038–6045. <https://doi.org/10.1021/acsnano.0c10945>
6. Koya A.N., Cunha J., Guo T.-L., Toma A., Garoli D., Wang T., Juodkazis S., Zaccaria D.P., Novel R. Novel plasmonic nanocavities for optical trapping-assisted biosensing applications // *Advanced Optical Materials*. 2020. V. 8. N 7. P. 1901481. <https://doi.org/10.1002/adom.201901481>
7. Stockman M.I. Electromagnetic Theory of SERS // *Topics in Applied Physics*. 2006. V. 103. P. 47–65. [https://doi.org/10.1007/3-540-33567-6\\_3](https://doi.org/10.1007/3-540-33567-6_3)
8. Бланк Т.В., Гольдберг Ю.А. Механизмы протекания тока в омических контактах металл-полупроводник // Физика и техника полупроводников. 2007. Т. 41. № 11. С. 1281–1290.
9. Watanabe T., Gerischer H. Electronically excited water aggregates and the adiabatic band gap of water // *Journal of Electroanalytical Chemistry*. 1981. V. 122. P. 73–80.
10. Uskov A.V., Protsenko I.E., Ikhsanov R.S., Babicheva V.E., Zhukovsky S.V., Lavrinenco A.V., O'Reilly E.P., Xu H. Internal photoemission from plasmonic nanoparticles: comparison between surface and volume photoelectric effects // *Nanoscale*. 2014. V. 6. N 9. P. 4716–4721. <https://doi.org/10.1039/C3NR06679G>
11. Graf M., Vonbun-Feldbauer G.B., Koper M.T.M. Direct and broadband plasmonic charge transfer to enhance water oxidation on a gold electrode // *ACS Nano*. 2021. V. 15. N 2. P. 3188–3200. <https://doi.org/10.1021/acsnano.0c09776>
12. Jia H., Wong Y.L., Wang B., Xing G., Tsoi C., Wang M., Zhang W., Jian A., Sang S., Lei D., Zhang X. Enhanced solar water splitting using plasmon-induced resonance energy transfer and unidirectional charge carrier transport // *Optics Express*. 2021. V. 29. N 21. P. 34810–34825. <https://doi.org/10.1364/OE.440777>
13. Безруков П.А., Нащекин А.В., Никоноров Н.В., Сидоров А.И. Морфологические особенности микро- и нанопористых пленок из серебра и меди, синтезированных методом реакции замещения // Физика твердого тела. 2022. Т. 64. № 8. С. 1096–1100. <https://doi.org/10.21883/FTT.2022.08.52713.342>
14. Jiao Y., Chen M., Ren Y., Ma H. Synthesis of three-dimensional honeycomb-like Au nanoporous films by laser induced modification and its application for surface enhanced Raman spectroscopy // *Optical Materials Express*. 2017. V. 7. N 5. P. 1557–1464. <https://doi.org/10.1364/OME.7.001557>

## Авторы

**Сидоров Александр Иванович** — доктор физико-математических наук, доцент, ведущий научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация; профессор, Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Санкт-Петербург, 197022, Российская Федерация, sc 57193232588, <https://orcid.org/0000-0001-8730-4389>, [sidorov@oi.ifmo.ru](mailto:sidorov@oi.ifmo.ru)

## References

1. Morales-Guio C.G., Tilley S.D., Vrubel H., Grätzel M., Hu X. Hydrogen evolution from a copper(I) oxide photocathode coated with an amorphous molybdenum sulphide catalyst // *Nature Communications*, 2014, vol. 5, pp. 3059. <https://doi.org/10.1038/ncomms4059>
2. Walter M.G., Warren E.L., McKone J.R., Boettcher S.W., Mi Q., Santori E.A., Lewis N.S. Solar water splitting cells. *Chemical Reviews*, 2010, vol. 110, no. 11, pp. 6446–6478. <https://doi.org/10.1021/cr1002326>
3. Ben-Shahar Y., Scogognella F., Kriegel I., Moretti L., Cerullo G., Rabani E., Banin U. Optimal metal domain size for photocatalysis with hybrid semiconductor-metal nanorods. *Nature Communications*, 2016, vol. 7, pp. 10413. <https://doi.org/10.1038/ncomms10413>
4. Gan J., Lu X., Tong Y. Towards highly efficient photoanodes: boosting sunlight-driven semiconductor nanomaterials for water oxidation. *Nanoscale*, 2014, vol. 6, no. 13, pp. 7142–7152. <https://doi.org/10.1039/c4nr01181c>
5. Koya A.N., Zhu X., Ohannesian N., Yanik A.A., Alabastri A., Zaccaria R.P., Krahne R., Shih R.K.W.-C., Garoli D. Nanoporous metals: From plasmonic properties to applications in enhanced spectroscopy and photocatalysis. *ACS Nano*, 2021, vol. 15, no. 4, pp. 6038–6045. <https://doi.org/10.1021/acsnano.0c10945>
6. Koya A.N., Cunha J., Guo T.-L., Toma A., Garoli D., Wang T., Juodkazis S., Zaccaria D.P., Novel R. Novel plasmonic nanocavities for optical trapping-assisted biosensing applications. *Advanced Optical Materials*, 2020, vol. 8, no. 7, pp. 1901481. <https://doi.org/10.1002/adom.201901481>
7. Stockman M.I. Electromagnetic Theory of SERS. *Topics in Applied Physics*, 2006, vol. 103, pp. 47–65. [https://doi.org/10.1007/3-540-33567-6\\_3](https://doi.org/10.1007/3-540-33567-6_3)
8. Blank T.V., Gol'dberg Yu.A. Mechanisms of current flow in metal-semiconductor ohmic contacts. *Semiconductors*, 2007, vol. 41, no. 22, pp. 1263–1269. <https://doi.org/10.1134/S1063782607110012>
9. Watanabe T., Gerischer H. Electronically excited water aggregates and the adiabatic band gap of water. *Journal of Electroanalytical Chemistry*, 1981, vol. 122, pp. 73–80.
10. Uskov A.V., Protsenko I.E., Ikhsanov R.S., Babicheva V.E., Zhukovsky S.V., Lavrinenco A.V., O'Reilly E.P., Xu H. Internal photoemission from plasmonic nanoparticles: comparison between surface and volume photoelectric effects. *Nanoscale*, 2014, vol. 6, no. 9, pp. 4716–4721. <https://doi.org/10.1039/C3NR06679G>
11. Graf M., Vonbun-Feldbauer G.B., Koper M.T.M. Direct and broadband plasmonic charge transfer to enhance water oxidation on a gold electrode. *ACS Nano*, 2021, vol. 15, no. 2, pp. 3188–3200. <https://doi.org/10.1021/acsnano.0c09776>
12. Jia H., Wong Y.L., Wang B., Xing G., Tsoi C., Wang M., Zhang W., Jian A., Sang S., Lei D., Zhang X. Enhanced solar water splitting using plasmon-induced resonance energy transfer and unidirectional charge carrier transport. *Optics Express*, 2021, vol. 29, no. 21, pp. 34810–34825. <https://doi.org/10.1364/OE.440777>
13. Bezrukov P.A., Nashchekin A.V., Nikonorov N.V., Sidorov A.I. Morphological features of micro- and nanoporous silver and copper films synthesized by the substitution reaction method. *Physics of the Solid State*, 2022, vol. 64, no. 8, pp. 1106–1110. <https://doi.org/10.21883/pss.2022.08.54634.342>
14. Jiao Y., Chen M., Ren Y., Ma H. Synthesis of three-dimensional honeycomb-like Au nanoporous films by laser induced modification and its application for surface enhanced Raman spectroscopy. *Optical Materials Express*, 2017, vol. 7, no. 5, pp. 1557–1464. <https://doi.org/10.1364/OME.7.001557>

## Authors

**Alexander I. Sidorov** — D.Sc. (Physics & Mathematics), Associate Professor, Leading Researcher, ITMO University, Saint Petersburg, 197101, Russian Federation; Professor, Saint Petersburg State Electrotechnical University “LETI”, Saint Petersburg, 197022, Russian Federation, sc 57193232588, <https://orcid.org/0000-0001-8730-4389>, [sidorov@oi.ifmo.ru](mailto:sidorov@oi.ifmo.ru)

**Нащекин Алексей Викторович** — кандидат физико-математических наук, старший научный сотрудник, Физико-технический институт им. А.Ф. Иоффе, Санкт-Петербург, 194021, Российская Федерация, [sc 6603372975](https://orcid.org/0000-0002-2542-7364), <https://orcid.org/0000-0002-2542-7364>, nashchekin@mail.ioffe.ru

**Никоноров Николай Валентинович** — доктор физико-математических наук, доцент, ведущий научный сотрудник, профессор, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 7003772604](https://orcid.org/0000-0002-1341-067X), <https://orcid.org/0000-0002-1341-067X>, nikonorov@oi.ifmo.ru

Статья поступила в редакцию 29.07.2024

Одобрена после рецензирования 31.08.2024

Принята к печати 25.09.2024

**Aleksey V. Nashchekin** — PhD (Physics & Mathematics), Senior Researcher, Ioffe Institute, Saint Petersburg, 194021, Russian Federation, [sc 6603372975](https://orcid.org/0000-0002-2542-7364), <https://orcid.org/0000-0002-2542-7364>, nashchekin@mail.ioffe.ru

**Nikolay V. Nikonorov** — D.Sc. (Physics & Mathematics), Associate Professor, Leading Researcher, Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 7003772604](https://orcid.org/0000-0002-1341-067X), <https://orcid.org/0000-0002-1341-067X>, nikonorov@oi.ifmo.ru

Received 29.07.2024

Approved after reviewing 31.08.2024

Accepted 25.09.2024



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»

## ТРЕБОВАНИЯ К ОФОРМЛЕНИЮ СТАТЕЙ

Журнал публикует научные обзоры, полнотекстовые статьи и краткие сообщения.

Полнотекстовая статья должна иметь четкую структуру, включающую в себя аннотацию, ключевые слова, введение, несколько содержательных разделов и заключение.

В аннотации, рассчитанной на самый широкий круг читателей, необходимо в объеме 200–400 слов в форме краткого реферата (*Abstract*) изложить научное содержание статьи: предмет, цель работы, метод или методология проведения работы, краткое описание эксперимента, полученные результаты, рекомендации по их применению.

Ключевые слова должны отражать информацию, представленную в статье. Основное ключевое слово указывается первым.

В введении необходимо представить содержательную постановку рассматриваемого вопроса, провести краткий анализ известных из научной литературы решений (со ссылками на источники), дать критику их недостатков, показать научную новизну и преимущество (особенности) предлагаемого подхода.

В основном тексте статьи должна быть представлена строгая постановка решаемой задачи, изложены и обстоятельно разъяснены (доказаны) полученные утверждения и выводы, приведены результаты экспериментальных исследований или математического моделирования, иллюстрирующие сделанные утверждения. Основной текст статьи должен быть разбит на содержательные разделы (2–3 раздела).

В заключении необходимо кратко сформулировать основные результаты, прокомментировать их и, если возможно, указать направления дальнейших исследований и области применения.

Пристатейный список литературы (рекомендуется): для обзорной статьи — не менее 50, для полнотекстовой статьи — не менее 15, для краткого сообщения — не менее 8 литературных источников.

Ссылки на стандарты и иные нормативные документы, а также на неперсонифицированные интернет-ресурсы в список литературы не вносятся, а оформляются в виде сносок.

Объем обзорной статьи предварительно согласовывается с редакцией.

Объем полнотекстовой статьи, включая иллюстрации, таблицы и список литературы, не должен превышать 8 страниц машинописного текста (с рисунками и таблицами), шрифт 12 pt, один интервал.

Объем краткого сообщения — до 3 страниц, шрифт 12 pt, один интервал. Рубрикация текста не требуется. Статьи принимаются в электронном виде ([ntvitmo@itmo.ru](mailto:ntvitmo@itmo.ru)). В распечатанном виде с подписями авторов материалы представляются в редакцию по запросу редакции после прохождения процедуры рецензирования.

Комплект документов должен включать:

- текст статьи с заверстанными рисунками и таблицами;
- формы сведений об авторах (на каждого автора); допускается указание нескольких мест работы автора;
- файлы с рисунками к статье в оригинальном формате (предпочтительно JPEG) с максимальным разрешением; допускается представление цветных рисунков, если в черно-белом варианте теряется полезная информация;
- лицензионное соглашение;
- согласие на обработку персональных данных.

## REQUIREMENTS FOR EXECUTION OF PAPERS

Scientific reviews, full-text and brief papers are published.

A full-text paper should have a well-defined structure, including an abstract, keywords, introduction, several substantive chapters and a conclusion.

An abstract is intended for general public. It is necessary to set forth the scientific content of the paper limited by 200–400 words in the form of a brief abstract: the subject, the work objective, the method or methodology of work, a brief description of the experiment, obtained results, recommendations for their application.

Keywords should be connected with the information presented in the paper. The main keyword is given first.

The introduction should contain a meaningful statement of the issue in question, a brief analysis of the solutions known from scientific literature (with references to sources), a criticism of their shortcomings, scientific novelty and advantages (features) of the proposed approach.

The main body of the paper should represent exact statement of the problem being solved, obtained assertions and conclusions are to be set forth and explained in detail (proved), the results of experimental studies or mathematical modeling should be given to illustrate the statements made. The main text of the paper needs to be split up into meaningful sections (2–3 sections).

In conclusion it is necessary to summarize the main results, comment on them and, if possible, to indicate the areas of future research and application.

A list of references is recommended: for a review paper — at least 50 items, for full-text paper — not less than 15, for a brief paper — at least 8 references. References to standards and other regulatory documents, as well as to Internet resources, are not included in a reference list and are documented as footnotes.

The length of a review paper is coordinated with the editorial board beforehand.

The length of a full-text paper, including illustrations, tables and references, should not exceed 8 pages of typewritten text (figures and tables included), font 12 pt, single-spaced.

The length of a brief paper is up to 3 pages, font 12 pt, single-spaced.

No rubrication is required.

Papers are accepted in electronic form ([ntvitmo@itmo.ru](mailto:ntvitmo@itmo.ru)).

Materials are submitted to the editors on request after the procedure of reviewing in a printed form signed by the authors.

A set of documents should include:

- The text of the paper with make-up figures and tables;
- The forms with information about the authors (for each author), several employers can be specified by the author;
- Files with pictures to the paper in their original format (preferably JPEG) with the maximum resolution; should useful information is lost in the black and white variant, color drawings are permitted;
- Publishers license agreement;
- Consent to the processing of personal data.

# INFORMATION TECHNOLOGIES, MECHANICS AND OPTICS

2024, VOLUME 24, NUMBER 5 (SEPTEMBER–OCTOBER)

ISSN 2226-1494 (PRINT), 2500-0373 (ONLINE)

**REVIEW PAPERS**

Automatic sign language translation: a review of neural network methods for recognition and synthesis of spoken and signed language

Overview of routing algorithms for network on chip

*Ivanko D.V., Ryumin D.A.*

669

**OPTICAL ENGINEERING**

Investigation of the characteristics of a semiconductor laser diode as a transceiver for fiber Bragg gratings interrogation

Gain characteristics of  $\text{In}_{0.60}\text{Ga}_{0.40}\text{As}/\text{In}_{0.53}\text{Al}_{0.20}\text{Ga}_{0.27}\text{As}$  superlattice active regions for vertical-cavity surface-emitting lasers

*Bondarenko M.I., Platunov A.E.*

687

Change of optical properties of silver surface due to laser structuring

Algorithm for navigation on the terrain of unmanned aerial vehicles with machine vision

Development of a fiber-optic system for monitoring geotechnical structures

*Oshlakov V.S., Aleinik A.S., Volkovskiy S.A., Smirnov D.S.*

699

*Kopytov P.E., Andryushkin V.V., Pirogov E.V., Sobolev M.S., Babichev A.V., Shernyakov Yu.M., Maximov M.V., Lyutetskiy A.V., Pikhtin N.A., Karachinsky L.Ya., Novikov I.I., Tian Sicong, Egorov A.Yu.*

709

*Morozova A.A., Kapustina U.A., Lutoshina D.S., Romanova G.V.*

717

*Zikratov I.A., Belyaev P.U., Neverov E.A.*

726

*Nikulin I.N., Rofer Yu.I.*

738

**AUTOMATIC CONTROL AND ROBOTICS**

Control of nonlinear plants with a guarantee for the controlled signal to stay within a given set under disturbances and high-frequency measurement noises

*Wen Xu., Furtat I.B.*

745

**MATERIAL SCIENCE AND NANOTECHNOLOGIES**

Impact of solvent quality on tribological properties of polymer brushes

*Lukiev I.V., Mikhailov I.V., Borisov O.V.*

751

**COMPUTER SCIENCE**

Low-complexity multi task learning for joint acoustic scenes classification and sound events detection

*Surkov M.K.*

758

A method for optimizing neural networks based on structural distillation using a genetic algorithm

*Kuzmin V.N., Menisov A.B., Sabirov T.R.*

770

ViSL model: The model automatically generates sentences of Vietnamese sign language (in English)

*Dang Kh., Bessmertny I.A.*

779

Enhanced anomaly detection in network security: a comprehensive ensemble approach (in English)

*Pandey R., Pandey M., Nazarov A.N.*

788

Enhancing attribute-based access control with Ethereum and ZK-SNARK technologies (in English)

*Maalla M., Bezzateev S.V.*

797

Comparative analysis of neural network models for felling mapping in summer satellite imagery

*Melnikov A.V., Polishchuk Yu.M., Rusanov M.A., Abbazov V.R., Kochergin G.A., Kupriyanov M.A., Baisalyamova O.A., Sokolkov O.I.*

806

Guaranteed estimates of the gamma percent residual life of data storage equipment

*Lomakin M.I., Dokukin A.V., Oltyan I.Yu., Niyazova Yu.M., Divya M., Dhilipan J., Saravanan A.*

815

Classification of multiple sclerosis lesion through Deep Learning analysis of MRI images (in English)

824

Creation and analysis of multimodal corpus for aggressive behavior recognition

*Uzdiaev M.Yu., Karpov A.A.*

834

Single images 3D reconstruction by a binary classifier (in English)

843

Obfuscated malware detection using deep neural network with ANOVA feature selection on CIC-MalMem-2022 dataset (in English)

*Resen S.A.*

849

**MODELING AND SIMULATION**

Switched reluctance motor flux linkage characteristic: experimental approach

*Hadjila M., Merzoug M., Ferhi W., Moussaoui D., Boudaine A.B., Hachemi M.H.*

858

**BRIEF PAPERS**

Spectral dependence of photoelectrochemical water splitting by silver nanoporous layers

*Yaremenko A.M., Demidova G.L., Sorokina A.A., Mamatov A.G., Bogdanov A.N., Anuchin A.S.*

858

*Sidorov A.I., Nashchekin A.V., Nikonorov N.V.*

866