

ISSN 1684-8853 (print); ISSN 2541-8610 (online)

ИНФОРМАЦИОННО- УПРАВЛЯЮЩИЕ СИСТЕМЫ

НАУЧНЫЙ ЖУРНАЛ

1(128)/2024

1(128)/2024

PEER REVIEWED JOURNAL

INFORMATSIONNO- UPRAVLIAIUSHCHIE SISTEMY (INFORMATION AND CONTROL SYSTEMS)

Founder

A. Vostrikov

PublisherSaint Petersburg State University
of Aerospace Instrumentation**Editor-in-Chief**

E. Krouk

Dr. Sc., Professor, Moscow, Russia

Executive secretary

O. Muravtsova

Editorial Board

S. Andreev

Dr. Sc., Tampere, Finland

V. Anisimov

Dr. Sc., Professor, Saint Petersburg, Russia

B. Bezruchko

Dr. Sc., Professor, Saratov, Russia

N. Blaunstein

Dr. Sc., Professor, Beer-Sheva, Israel

M. Buzdalov,

PhD, Researcher, Saint Petersburg, Russia

C. Christodoulou

PhD, Professor, Albuquerque, New Mexico, USA

A. Dudin

Dr. Sc., Professor, Minsk, Belarus

I. Dumer

PhD, Professor, Riverside, USA

M. Favorskaya

Dr. Sc., Professor, Krasnoyarsk, Russia

L. Fortuna

PhD, Professor, Catania, Italy

A. Fradkov

Dr. Sc., Professor, Saint Petersburg, Russia

A. Hramov

Dr. Sc., Professor, Innopolis, Russia

L. Jain

PhD, Professor, Canberra, Australia

G. Matvienko

Dr. Sc., Professor, Tomsk, Russia

A. Myllari

PhD, Professor, Grenada, West Indies

K. Samouylov

Dr. Sc., Professor, Moscow, Russia

J. Seberry

PhD, Professor, Wollongong, Australia

M. Sergeev

Dr. Sc., Professor, Saint Petersburg, Russia

A. Shalyto

Dr. Sc., Professor, Saint Petersburg, Russia

A. Shepeta

Dr. Sc., Professor, Saint Petersburg, Russia

Yu. Shokin

RAS Academician, Dr. Sc., Novosibirsk, Russia

A. Smirnov

Dr. Sc., Professor, Saint Petersburg, Russia

T. Sutikno

PhD, Associate Professor, Yogyakarta, Indonesia

Z. Yuldashev

Dr. Sc., Professor, Saint Petersburg, Russia

R. Yusupov

RAS Corr. Member, Dr. Sc., Professor, Saint Petersburg, Russia

A. Zeifman

Dr. Sc., Professor, Vologda, Russia

Editor: A. Larionova**Proofreader:** T. Zvertanovskaia**Design:** M. Chernenko, Yu. Umnitsyna**Layout and composition:** Yu. Umnitsyna**Contact information**

The Editorial and Publishing Center, SUAI

67A, Bol'shaya Morskaya, 190000, Saint Petersburg, Russia

Website: <http://i-us.ru/en>, e-mail: i-us.spb@gmail.com

Tel.: +7 - 812 494 70 02

THEORETICAL AND APPLIED MATHEMATICS*Balonin N. A., Sergeev A. M., Sergeev M. B. Matrices of the Hadamard family as slices of an orthogonal hyperobject at adjacent orders*

2

INFORMATION PROCESSING AND CONTROL*Gruzdev N. V., Shuvaev F. L. Determination of the optimal set of graph similarity metrics in problems of recognition of topologies of technogenic space objects*

9

INFORMATION AND CONTROL SYSTEMS*Miloserdov D. I. Advanced neural network forecasting system with continuous learning for grouped time series*

20

Belyaev A. S., Kushnarev O. Yu., Brylev O. A. Synthesis of a hybrid underlying surface classifier based on fuzzy logic using current consumption of mobile robot motion

31

INFORMATION SECURITY*Lipatnikov V. A., Shevchenko A. A., Melekhov K. V., Tkachev D. F. Methodology for improving the security of the data transmission network of critical information infrastructure objects under multi-stage attacks*

44

INFORMATION CHANNELS AND MEDIUM*Stepanov M. A., Sokolov V. S. Ratios for calculating the radiation pattern of MIMO radar with different antennas of receiving and transmitting elements forming it*

56

INFORMATION ABOUT THE AUTHORS

64

Submitted for publication 12.01.24. Passed for printing 29.02.24. Signed for printing: 04.03.2024.
Format 60×84_{1/8}. Phototype CentSchbkCyrill BT. Digital printing.

Layout original is made at the Editorial and Publishing Center, SUAI.

67A, Bol'shaya Morskaya, 190000, Saint Petersburg, Russia

Printed from slides at the Editorial and Publishing Center, SUAI.

67A, Bol'shaya Morskaya, 190000, Saint Petersburg, Russia

The journal is indexed in Scopus.

Free distribution.

1(128)/2024

РЕЦЕНЗИРУЕМОЕ ИЗДАНИЕ

ИНФОРМАЦИОННО-
УПРАВЛЯЮЩИЕ
СИСТЕМЫ

Учредитель

А. А. Востриков

Издатель

Санкт-Петербургский государственный университет

аэрокосмического приборостроения

Главный редактор

Е. А. Крук

д-р техн. наук, проф., Москва, РФ

Ответственный секретарь

О. В. Муравцова

Редакционная коллегия:

С. Д. Андреев,

д-р техн. наук, Тампере, Финляндия

В. Г. Анисимов,

д-р техн. наук, проф., Санкт-Петербург, РФ

Б. П. Безручко,

д-р физ.-мат. наук, проф., Саратов, РФ

Н. Блаунштейн,

д-р физ.-мат. наук, проф., Беэр-Шева, Израиль

М. В. Буэдалов,

канд. техн. наук, научный сотрудник, Санкт-Петербург, РФ

Л. С. Джайн,

д-р наук, проф., Канберра, Австралия

А. Н. Дудин,

д-р физ.-мат. наук, проф., Минск, Беларусь

И. И. Думер,

д-р наук, проф., Риверсайд, США

А. И. Зейфман,

д-р физ.-мат. наук, проф., Вологда, РФ

К. Кристоделу,

д-р наук, проф., Альбукерке, Нью-Мексико, США

Г. Г. Матвиенко,

д-р физ.-мат. наук, проф., Томск, РФ

А. А. Мюллари,

д-р наук, профессор, Гренада, Вест-Индия

К. Е. Самуилов,

д-р техн. наук, проф., Москва, РФ

Д. Себерри,

д-р наук, проф., Волонгонг, Австралия

М. Б. Сергеев,

д-р техн. наук, проф., Санкт-Петербург, РФ

А. В. Смирнов,

д-р техн. наук, проф., Санкт-Петербург, РФ

Т. Сутикнуоу,

д-р наук, доцент, Джокьякарта, Индонезия

М. Н. Фаворская,

д-р техн. наук, проф., Красноярск, РФ

Л. Фортуна,

д-р наук, проф., Катания, Италия

А. Л. Фрадков,

д-р техн. наук, проф., Санкт-Петербург, РФ

А. Е. Храмов,

д-р физ.-мат. наук, Иннополис, РФ

А. А. Шальто,

д-р техн. наук, проф., Санкт-Петербург, РФ

А. П. Шепета,

д-р техн. наук, проф., Санкт-Петербург, РФ

Ю. И. Шокин,

акад. РАН, д-р физ.-мат. наук, проф., Новосибирск, РФ

З. М. Юлдашев,

д-р техн. наук, проф., Санкт-Петербург, РФ

Р. М. Юсупов,

чл.-корр. РАН, д-р техн. наук, проф., Санкт-Петербург, РФ

Редактор: А. Г. Ларионова

Корректор: Т. В. Звертановская

Дизайн: М. Л. Черненко, Ю. В. Умницына

Компьютерная верстка: Ю. В. Умницына

Адрес редакции: 190000, г. Санкт-Петербург,

ул. Большая Морская, д. 67, лит. А, ГУАП, РИЦ

Тел.: (812) 494-70-02, эл. адрес: ius.spb@gmail.com,

сайт: http://i-us.ru

ТЕОРЕТИЧЕСКАЯ И ПРИКЛАДНАЯ МАТЕМАТИКА

Балонин Н. А., Сергеев А. М., Сергеев М. Б. Матрицы семейства Адамара как срезы ортогонального гиперобъекта на смежных порядках

2

ОБРАБОТКА ИНФОРМАЦИИ И УПРАВЛЕНИЕ

Груздев Н. В., Шуваев Ф. Л. Определение оптимального набора метрик подобия графов в задачах распознавания топологий техногенных космических объектов

9

ИНФОРМАЦИОННО-УПРАВЛЯЮЩИЕ СИСТЕМЫ

Милосердов Д. И. Усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением

20

Belyaev A. S., Kushnarev O. Yu., Brylev O. A. Synthesis of a hybrid underlying surface classifier based on fuzzy logic using current consumption of mobile robot motion

31

ЗАЩИТА ИНФОРМАЦИИ

Липатников В. А., Шевченко А. А., Мелехов К. В., Ткачев Д. Ф. Методика повышения защищенности сети передачи данных объектов критической информационной инфраструктуры при многоэтапных атаках

44

ИНФОРМАЦИОННЫЕ КАНАЛЫ И СРЕДЫ

Степанов М. А., Соколов В. С. Соотношения для расчета диаграммы направленности МИМО РЛС при различающихся антеннах приемных и передающих элементов, формирующих ее

56

СВЕДЕНИЯ ОБ АВТОРАХ

64

Журнал входит в БД Scopus и в Перечень рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученой степени кандидата наук, на соискание ученой степени доктора наук.

Сдано в набор 12.01.24. Подписано в печать 29.02.24. Дата выхода в свет: 04.03.2024.

Формат 60×841/8. Гарнитура CentSchbkCyrill BT. Печать цифровая.

Усл. печ. л. 7,8. Уч.-изд. л. 10,8. Тираж 1000 экз (1-й завод 50 экз.). Заказ № 39.

Оригинал-макет изготовлен в редакционно-издательском центре ГУАП.

190000, г. Санкт-Петербург, ул. Большая Морская, д. 67, лит. А.

Отпечатано в редакционно-издательском центре ГУАП.

190000, г. Санкт-Петербург, ул. Большая Морская, д. 67, лит. А.

Распространяется бесплатно.

Журнал зарегистрирован в Министерстве РФ по делам печати, телерадиовещания и средств массовых коммуникаций. Свидетельство о регистрации ПИ № 77-12412 от 19 апреля 2002 г. Перерегистрирован в Роскомнадзоре. Свидетельство о регистрации ПИ № ФС77-82226 от 23 ноября 2021 г. © А. А. Востриков, 2024



Матрицы семейства Адамара как срезы ортогонального гиперобъекта на смежных порядках

Н. А. Балонин^а, доктор техн. наук, профессор, orcid.org/0000-0001-7338-4920, korbendfs@mail.ru

А. М. Сергеев^а, канд. техн. наук, доцент, orcid.org/0000-0002-4788-9869

М. Б. Сергеев^а, доктор техн. наук, профессор, orcid.org/0000-0002-3845-9277

^аСанкт-Петербургский государственный университет аэрокосмического приборостроения, Б. Морская ул., 67, Санкт-Петербург, 190000, РФ

Введение: целочисленная постановка задачи поиска экстремальных по детерминанту матриц Адамара оставляет в неопределенности вопрос о том, завершаются ли итерации, которыми обычно ищется экстремум, целочисленными матрицами. Успешность разрешимости гипотезы Адамара о существовании всех таких матриц переборными методами малоэффективна в сравнении с методами некомбинаторной математики. **Цель:** показать разрешимость задачи поиска матриц семейства Адамара через срезы ортогонального гиперобъекта на смежных порядках, отвечающих последовательности натуральных чисел t . **Результаты:** выявлено, что, поскольку матрицы семейства Адамара определены инвариантами вложенных в их структуру матриц меньшего порядка, гиперобъект является универсальной основой для их совместного нахождения. Открытие феномена ортогонального гиперобъекта позволило уменьшить размер шага по порядкам порождаемых на его основе ортогональных матриц с $4t$ (для матриц Адамара) до t . **Практическая значимость:** ортогональные матрицы как результаты срезов ортогонального гиперобъекта существенно расширяют семейство матриц Адамара, имеющих большое практическое значение для задач ортогональных преобразований информации.

Ключевые слова – помехоустойчивое кодирование, матрицы Адамара, критские матрицы, ортогональный гиперобъект, алгоритм Прокруста, симметрии матриц.

Для цитирования: Балонин Н. А., Сергеев А. М., Сергеев М. Б. Матрицы семейства Адамара как срезы ортогонального гиперобъекта на смежных порядках. *Информационно-управляющие системы*, 2024, № 1, с. 2–8. doi:10.31799/1684-8853-2024-1-2-8, EDN: DSXAAV

For citation: Balonin N. A., Sergeev A. M., Sergeev M. B. Matrices of the Hadamard family as slices of an orthogonal hyperobject at adjacent orders. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 2–8 (In Russian). doi:10.31799/1684-8853-2024-1-2-8, EDN: DSXAAV

Введение

Теория ортогональных матриц Адамара как математических объектов принесла ощутимые практические результаты после успешных миссий нескольких космических автоматических станций к Марсу и к пределам Солнечной системы при кодировании передаваемых на Землю изображений [1, 2]. Ввиду помех в космическом канале связи именно использование ортогональных матриц Адамара H_n [1, 2] порядка n с двумя значениями элементов 1 и -1 , для которых выполняется $H_n^T H_n = nI_n$, где I_n – единичная матрица, позволило получить первые изображения из далекого космоса.

Для совершенствования методов преобразования информации, помехоустойчивого кодирования данных, защищенной передачи визуальных и аудиоданных по беспроводным каналам связи и др. [3–7] сегодня требуется широкое предложение ортогональных (квазиортогональных) матриц различных порядков и структур.

Развитие теории ортогональных матриц и совершенствование ее в части установления

фундаментальных связей порядков матриц и их структур можно рассматривать в связи с ортогональным гиперобъектом [8]. Причины, по которым гиперобъект становится основой для проведения научных и практических исследований, состоят в следующем: открытие феномена ортогонального гиперобъекта позволяет уменьшить размер шага по порядкам порождаемых на его основе ортогональных матриц с ограниченным количеством значений элементов с $4t$ (для матриц Адамара) до t , обеспечив связь их порядков со всеми числами t натурального ряда.

В работе [8] показано, что целочисленные матрицы Адамара являются всего лишь срезом более крупного математического объекта, который проявляет себя как иррациональная матрица. Можно отследить блочную структуру, симметрии, узоры из знаков элементов на портретах порождаемых матриц по мере формирования ее слоев по возрастанию порядков.

Отметим, что матрицы Адамара в классическом изложении никогда не увязывались ранее с такой широкой их трактовкой, как частный срез ортогонального гиперобъекта.

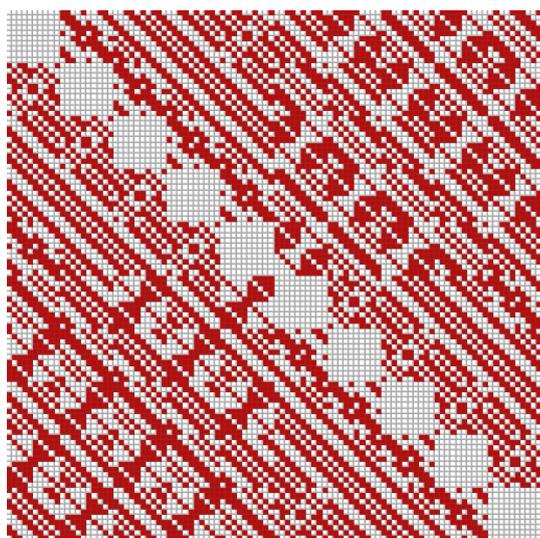
Цель настоящей статьи — показать, что проекциями гиперобъекта являются квазиортогональные матрицы с ограниченным числом значений элементов, обобщающие матрицы Адамара и существующие на смежных порядках.

Перспективы изучения ортогонального гиперобъекта

Для поиска ортогональных иррациональных матриц применимы не переборные, а совершенно иные методы исследования [9], включая алгоритмы поиска условных экстремумов и точек типа «седло», теоремы о неподвижной точке отображения и др. Они же позволяют находить и сложные матрицы Адамара, какими являются матрицы Адамара типа Буша [10, 11] — самый сложный объект, исследуемый основателем теории спорадических групп З. Янко [12].

Например, комбинаторный алгоритм (переборного) поиска матрицы Адамара типа Буша порядка 100 [13] сопровождается примером с досадной опечаткой в кодовой последовательности 1 и -1 , вследствие чего матрица теряет ортогональность. Найти, где именно допущена опечатка, означает программирование алгоритма вновь по поверхностному его описанию, причем переборные процедуры на таких порядках требуют недель, а то и месяцев работы высокопроизводительного компьютера.

Использованная оптимизационная процедура [9, 14] на основе алгоритма Прокруста [8], увеличивая детерминант этой дефектной матрицы, исправила ее до верного решения (рис. 1). Здесь



■ **Рис. 1.** Портрет исправленной матрицы Адамара типа Буша

■ **Fig. 1.** Portrait of a corrected Hadamard matrix of the Bush type

единичные элементы представлены белым цветом, элементы со значениями -1 — красным. Такая возможность, вытекающая из экстремальных свойств матриц Адамара, принципиально нова и позволяет избежать длительных и малоуспешных переборов.

Это относится как к матрицам Адамара порядков $4t$, так и к матрицам их семейства на четных $4t - 2$ и нечетных $4t - 1$ и $4t + 1$ порядках. Таким способом они и были обнаружены, позволив сформулировать их общность идеей параллельных срезов одного единого ортогонального гиперобъекта. Более того, благодаря особенностям выявленного гиперобъекта появилась возможность не только исправлять дефектные матрицы Адамара, столь популярные в научных и прикладных исследованиях, но и получать новые ортогональные матрицы промежуточных порядков [8].

Понятно, что ранее не известный феномен требует тщательного исследования, обещающего, в частности, строгое научное доказательство гипотезы Адамара о существовании матриц на порядках $4t$.

В самом деле, целочисленная математика в этом случае, как и теория решений целочисленных уравнений Диофанта, упирается в неограниченную сложность узоров на портретах матриц Адамара. Подобная проблема стояла перед математикой при невозможности описать диагональ равнобедренного прямоугольного треугольника отношением двух целых величин. Потребовалась итерация Герона, и именно ее использует алгоритм Прокруста, которым осуществляется поиск иррациональных матриц как срезов гиперобъекта.

Цель и задачи исследования ортогонального гиперобъекта

Основная цель развития и совершенствования теории ортогональных и экстремальных матриц сегодня состоит в установлении фундаментальных связей их существования, порядков и структурных инвариантов с помощью ортогонального гиперобъекта. Это открывает возможность формирования библиотеки уникальных ортогональных и экстремальных матриц для совершенствования существующих [4, 5] и разработки новых методов преобразования цифровой информации с использованием новых оригинальных матриц, сходных с адамаровыми [15].

Содержание научных и научно-технических задач, подлежащих решению при изучении гиперобъекта, следует формировать как изучение его проекций на соответствующие базисы.

Во-первых, стоит задача исследования применения ортогонального гиперобъекта как основы поиска очень разных групп ортогональных ма-

триц и последовательностей порядков, на кото-
рых они существуют.

Во-вторых, стоит задача изучения тактики ис-
пользования гиперобъекта и другой абстрактной
математики для поиска ортогональных матриц
с симметриями, а также выхода за пределы их
применимости – на составные порядки матриц и
длины порождающих их последовательностей [16].

Единство дискретной и континуальной мате-
матики как нельзя лучше демонстрируют крит-
ские матрицы, в частности, иррациональные
матрицы Мерсенна M_n такие, что $M_n^T M_n = \omega(n)I_n$,
где $\omega(n)$ – функция, определяющая эти матрицы
с вещественными элементами 1 и $-b$ в них или
образующих их блоках. В современной литерату-
ре принято называть эти и подобные им матри-
цы критскими (горными), подчеркивая нецело-
численность значений их элементов [3].

В отличие от матриц Адамара они заданы ус-
ловием локального оптимума детерминанта на
множестве матриц порядка $n = 4t - 1$ с элемен-
тами, не превышающими по модулю единицу.
Локальный максимум означает, что при малой
вариации элементов матрицы M_n детерминант
будет только уменьшаться. На третьем порядке
экстремум к тому же глобален, но уже на порядке 7
есть решения лучшие по детерминанту (абсо-
лютные экстремумы), но они стоят особняком.
От прочих таких оптимумов матрицы Мерсенна
отличает функция значения их элементов
 $b = t/(t + \text{sqrt}(t))$, входящая в их определение: е-
ли значение иное, то это не матрица Мерсенна.
Относительно слабый оптимум гарантирует
этим ортогональным матрицам существование
на всех порядках $n = 4t - 1$.

Гиперобъект в виде бициклической матрицы
Эйлера порядка 14 E_{14} , матриц M_{15} и H_{16} показан
последовательными срезами порядков $n = 4t - 2$,
 $n = 4t - 1$, $n = 4t$ на рис. 2 для $t = 4$.

Бициклические матрицы Эйлера на поряд-
ках $n = 4t - 2$ отличает функция значения эле-
ментов $b = t/(t + \text{sqrt}(2t))$ двух циклических бло-

ков. Удвоив, например, матрицу M_3 по формуле
Сильвестра без изменения значения b , получим
матрицу Эйлера четного порядка E_6 , а добавив
бинарную кайму, как на рис. 2 из элементов 1
и $-b$, вновь получим матрицу Мерсенна следую-
щего порядка M_7 . Еще одна кайма из 1 для $-M_7$
порождает матрицу Адамара с элементами 1 и -1 .

Этот алгоритм можно продолжить, получив,
например, стартовую матрицу E_{14} и далее M_{15} и
 H_{16} , представленные на рис. 2.

Обратим внимание, что появился выбор ис-
пользовать срез гиперобъекта как:

- бициклическую матрицу, получая малый
уровень дублирования блоков;
- матрицу, сформированную из матрицы
Мерсенна M_3 .

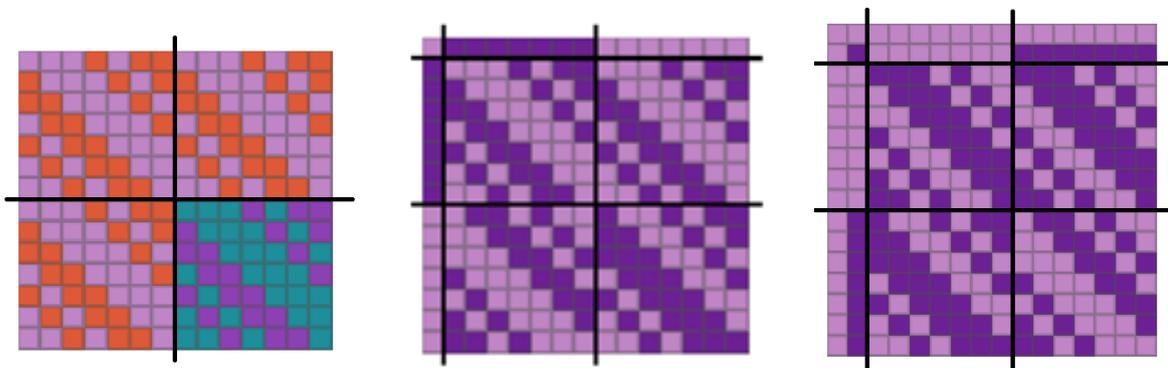
Различие узоров матриц можно использовать
при обмене кодированной (маскированной) ин-
формацией с ключом, соответствующим уровню
вложенности структуры матрицы.

Можно ли матрицу H_{16} нарастить каймой до
порядка 17?

Можно, и это будет еще одним срезом гипер-
объекта, но порядком выше. Особенность среза выше
состоит в том, что он реализуем только для регуляр-
ных матриц Адамара с равными суммами элементов
строк и столбцов – родственников магических ква-
дратов. Главная последовательность порядков при
этом равна числам Ферма 3, 5, 17, ... Такие матрицы
получили название матриц Ферма [8].

Указанные срезы можно использовать и для
матриц Белевича четных порядков $2t$. Таким об-
разом, порядки совокупности ортогональных ир-
рациональных матриц покрывают натуральные
числа. Причем структура этих матриц отвечает ха-
рактеру и особенностям чисел. Так, существует ма-
трица золотого сечения [13] со значением элемента
 $b = 0,618...$, и это единственная матрица поряд-
ка 10, не входящего в числовые последовательно-
сти, как у матриц Адамара, Мерсенна или Ферма.

Исследование гиперобъекта показывает, что
последовательности натуральных чисел отве-



■ **Рис. 2.** Портреты срезов гиперобъекта порядков 14, 15 и 16
■ **Fig. 2.** Portraits of slices of orders 14, 15 and 16 of the hyperobject

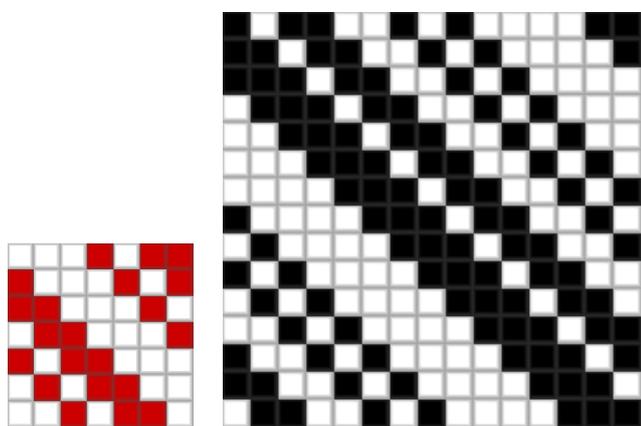
чает строение ортогональных базисов соответствующих порядков. Простым числам отвечают простые ортогональные матрицы с признаками явной симметрии, а составным — матрицы сложных структур [16]. Есть и особые матрицы на порядках, равных знаменитым в истории математики числам. Например, открытый Гауссом правильный семнадцатиугольник — это не единственный объект, сопровождающий число Ферма 17. Найдена взаимно однозначно отвечающая ему ортогональная матрица Ферма — объект совершенно иной природы, не геометрический, а малоизвестный в научной литературе матричный объект [8].

Свойства гиперобъекта

Поскольку гиперобъект представлен не одним, а серией порядков, среди которых выделяется нечетный между парой четных порядков, то очевидно, что его свойства отражают то, к каким множествам чисел относится этот нечетный порядок $n = 4t - 1$.

Так, например, кососимметрическая с точностью до диагонали циклическая матрица Мерсенна порядка 7 (рис. 3) отражает структуры всех таких матриц простого порядка, независимо от величины числа. Обнаружение М. Холлом [3] циклической матрицы Мерсенна порядка 15 (см. рис. 3), казалось бы, нарушает строгость следования числовой системе. На самом деле, вторая матрица и все такие матрицы, порядок которых равен произведению двух соседних нечетных значений $n = 3 \times 5$, серьезно отличается от матриц первого типа тем, что они не кососимметричны.

Таким образом, случайностей в типах симметрии срезов гиперобъекта нет. Матрица не может



■ **Рис. 3.** Портреты срезов порядков 7 и 15 в сопоставлении

■ **Fig. 3.** Portraits of slices of orders 7 and 15 in comparison

приобрести или потерять без причины определенный тип симметрии. Речь не идет об эквивалентных структурах, получаемых перестановками строк и столбцов или инверсией знаков строк и столбцов. На этом может быть построен путь для следующего доказательства существования всех симметричных матриц Адамара.

Дело в том, что числовая система, которой следуют свойства срезов гиперобъекта, относительно бедна в главном своем качестве. Все числа делятся на простые и составные. Какого-либо третьего вида чисел, отличающегося от этих двух, не существует. Этим можно воспользоваться.

Так, например, еще до того, как началось исследование матриц Адамара, их основные типы симметрии не были известны. Специалист по теории чисел У. Скарпи еще в конце XIX столетия опубликовал статью, в которой показал, что, помимо матриц Адамара порядков $n = q + 1$, где q — простое число, всегда может быть построена матрица порядка $q(q + 1)$ [1].

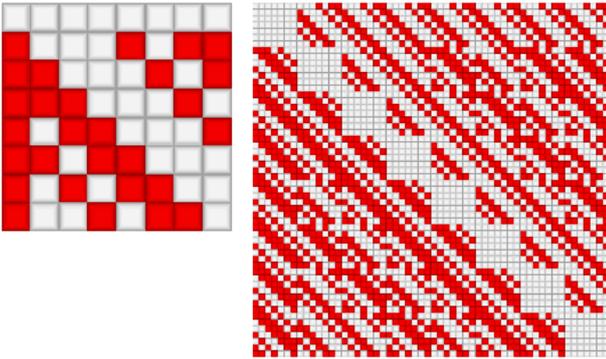
Поскольку Адамар сумел найти всего две новые матрицы порядков 12 и 20, отличающихся от последовательности Сильвестра, Скарпи нашел новую ортогональную матрицу заметно большего порядка 56 (7×8). Кроме того, его метод позволяет находить бесконечное число таких матриц, образующих отличное отдельными своими представителями семейство. Позднее Пэли [1, 3, 4] расширил область существования матриц порядков $q(q + 1)$ на случаи, когда q — степень простого числа. Расширенный алгоритм Скарпи, впрочем, настолько мало известен, что его переткрывают заново в настоящее время.

Таким образом, складывается впечатление, что порядки $q(q + 1)$ однозначно связаны с системой простых чисел. Причем это убеждение, помноженное на авторитет алгебраистов, занимавшихся данной проблемой, распространено настолько широко, что попало в справочники [3, 4]. Это впечатление ошибочно, оно легко разрушается контрпримерами блочных матриц порядка $q(q + 1)$, для которых простота числа q не играет той роли, которую придавали ей основоположники теории блочных матриц Скарпи и Пэли.

Оказывается, и в этом состоит смысл нашего нового предложения, секрет более быстрого и более универсального алгоритма заключается в перестановке сомножителей с модификацией не каймы (как у Скарпи [1]), а диагонали:

$$\mathbf{H} \times \mathbf{M} = \begin{pmatrix} \mathbf{J} & h_{12}\mathbf{M} & \dots & h_{1n}\mathbf{M} \\ h_{21}\mathbf{M} & \mathbf{J} & \dots & h_{2n}\mathbf{M} \\ \dots & \dots & \ddots & \dots \\ h_{n1}\mathbf{M} & h_{n2}\mathbf{M} & \dots & \mathbf{J} \end{pmatrix},$$

где \mathbf{J} — матрица из единиц (рис. 4).



■ **Рис. 4.** Портреты матриц Адамара порядков 8 и 56
 ■ **Fig. 4.** Portraits of Hadamard matrices of orders 8 and 56

Заметим, что основа (core) матрицы Адамара порядка 8 совпадает, с точностью до знака, с кососимметричной матрицей Мерсенна, приведенной на рис. 3. Этот алгоритм фундаментально отличен от предлагаемого Скарпи тем, что в нем нет циклических сдвигов вставляемых блоков, есть только следование знакам.

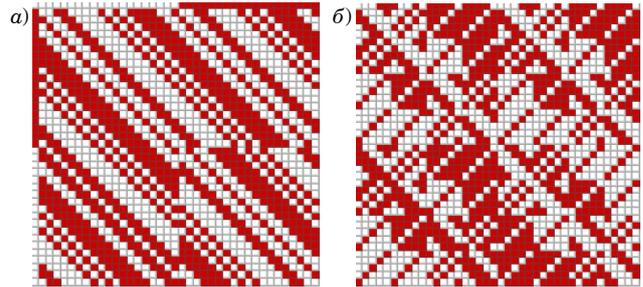
Кососимметричность матриц Адамара

В числовой системе, как мы ранее отмечали, ничего случайного не бывает, поэтому все матрицы Адамара порядков $q(q + 1)$ разлагаются на кососимметричные (с точностью до диагонали) сомножители простых или составных порядков q . Множество порядков q накрывает все матрицы Мерсенна $n = 4t - 1$, и, следовательно, то же самое относится и к матрицам Адамара порядков $n = 4t$.

Приведенный контрпример не единственный, однако даже его достаточно для разрушения тезиса о необходимости простоты значения q . Кососимметричный сомножитель составного порядка $q = 3 \times 13 = 39$ не только существует, но и несложно найти матрицы двух видов узора на портретах, приведенных на рис. 5, а и б.

С одной стороны, матрица Мерсенна M_{39} состоит из матрицы Эйлера E_{38} с каймой. Плечами E_{38} является кососимметричная матрица M_{19} , а 19 — простое число. С другой стороны, можно опираться на кососимметричную матрицу H_{20} из блоков **A**, **B**, **C** и **D** конструкции Себерри [3], удвоить ее алгоритмом Сильвестра [1, 3] до порядка 40 и выделить из нее отсечением каймы необходимую для построения матрицу M_{39} .

Последний путь не нуждается в предположениях о простоте блоков, что усложняет вид портрета матрицы Мерсенна, но не отменяет факта ее существования. Такие кососимметричные сомножители позволяют в рамках на-



■ **Рис. 5.** Портреты матриц Мерсенна порядка 39 (а) и Адамара порядка 40 (б)
 ■ **Fig. 5.** Portraits of the Mersenne matrix of order 39 (а) and Hadamard matrix of order 40 (б)

шего контрпримера построить не одну, а две матрицы Адамара отмеченной конструкции, не разрешимой методом Скарпи для порядка $q(q + 1) = 39 \times 40 = 1560$.

Таким образом, наше доказательство дополнительно к доказательству, приведенному в работе [6], опирается на фундаментальный факт: виды портретов ортогональных матриц Адамара жестко связаны с числовой системой. Кососимметрия множителей $q(q + 1)$, как видно, не зависит от того, простое число q или составное. Таким образом, кососимметричные матрицы Адамара определено существуют как члены таких разложений.

Нет оснований полагать, что деление на симметричные и кососимметричные конструкции матриц выделяет второй вид каким-либо особым фактом ее существования. Разумеется, существуют симметричные матрицы Адамара всех выделенных Адамаром порядков $4t$, в частности, блочной конструкции Пропус [3, 6]. Это конструкция из блоков **A**, **B** = **C** и **D**, альтернативная кососимметричной. Равенство двух блоков **B** и **C** позволяет построить симметричные матрицы, получившие в научной литературе название матриц Балонина — Себерри.

Существование обоих видов блочных матриц тесно связано с фундаментальной теоремой Гаусса о разложимости любого целого числа на сумму не более трех треугольных чисел. Эти три числа косвенно определяют количество элементов со значением -1 в строках трех циклических блоков **A**, **B** (**C**), **D** [3, 6]. У кососимметричных конструкций начальный блок, в силу кососимметрии, состоит из равного количества элементов со значениями 1 и -1 , за исключением диагонального элемента. То есть блоков, инварианты которых определяет теорема Гаусса, тоже три: **B**, **C** и **D**.

В конечном итоге задача о нахождении треугольных чисел (а значит, и матриц Адамара) сводится к классической задаче об определении числа точек Гаусса на поверхности сферы или сфероида

для конструкции Пропус [6]. Основной результат Гаусса состоит в том, что все интересные для нашей задачи порядки разрешимы. Именно эта теорема совместно с массивами составляет (помимо факта их существования) основу симметричных или кососимметричных матриц Адамара, присоединяя к ним прочие срезы гиперобъекта.

Все это в совокупности отвечает положительно на центральный для теории ортогональных матриц с малым числом элементов вопрос о разрешимости опорных порядков, кратных четырем. Отрицать этот факт — значит идти вразрез с утверждениями о строении числовой системы и содержании теоремы Гаусса, поскольку матрицы для нее — не более чем иллюстративный материал.

Заключение

Феномен ортогонального гиперобъекта был обнаружен в 2022 г. Это достаточно поздно, если считать, что поиск матриц Адамара — классическая область приложения методов комбинаторики, где отсутствует понятие экстремума.

Исследование ортогонального гиперобъекта как иррациональной матрицы направлено на поиск путей получения через его проекции экстремальных и ортогональных матриц семейства Адамара. Результаты исследования заключаются в ответах на вопросы об особенностях

взаимосвязи через гиперобъект разных групп матриц: целочисленных, рациональных и иррациональных, обладающих ортогональностью и (или) различными экстремальными свойствами.

Идея срезов гиперобъекта сильна тем, что затрагивает основы континуальной и дискретной математик. Целочисленные матрицы с их специфичным поиском комбинаторными алгоритмами поставлены во взаимно однозначное соответствие иррациональным матрицам, для поиска которых есть оптимизационные методы. Если иррациональная матрица может быть найдена, то найдется и целочисленная.

Формирование разнообразия экстремальных и ортогональных матриц семейства Адамара по порядкам и структурам является стимулом для пересмотра существующих и разработки новых методов ортогональных преобразований.

Финансирование

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации, соглашение № FSRF-2023-0003 «Фундаментальные основы построения помехозащищенных систем космической и спутниковой связи, относительной навигации, технического зрения и аэрокосмического мониторинга».

Литература

1. **Shalom E.** La conjecture de Hadamard (I) — images des mathématiques. CNRS, 2012. images.math.cnrs.fr/La-conjecture-de-Hadamard-I.html (дата обращения: 17.12.2023).
2. **Лейтон Р.** Поверхность Марса: пер. Л. В. Самсоенко. *Успехи физических наук*, 1971, т. 103, вып. 4, с. 755–768.
3. **Jennifer S., Yamada M.** *Hadamard Matrices: Constructions using Number Theory and Linear Algebra*. Wiley, 2020. 384 p.
4. **Horadam K. J.** *Hadamard Matrices and their Applications*. Princeton University Press, 2007. 263 p.
5. **Wang R.** *Introduction to Orthogonal Transforms with Applications in Data Processing and Analysis*. Cambridge University Press, 2010. 504 p.
6. **Востриков А. А., Балонин Ю. Н.** Матрицы Адамара — Мерсенна как базис ортогональных преобразований при маскировании видеоизображений. *Известия высших учебных заведений. Приборостроение*, 2014, т. 57, № 1, с. 15–19.
7. **Григорьев Е. К.** Анализ корреляционных характеристик новых кодовых последовательностей, основанных на персимметричных квазиортогональных циркулянтах. *Труды учебных заведений свя-*
8. **Балонин Н. А., Себерри Д., Сергеев М. Б.** Задачи разрешимые и неразрешимые. Алгоритм Прокруста получения матриц семейства Адамара. *Информационно-управляющие системы*, 2023, № 1, с. 2–16. doi:10.31799/1684-8853-2023-1-2-16
9. **Балонин Н. А., Сергеев М. Б., Суздаль В. С.** Динамические генераторы квазиортогональных матриц семейства Адамара. *Труды СПИИРАН*, 2017, № 5 (54), с. 224–243. doi:10.15622/sp.54.10
10. **Wallis W. D.** On a problem of K. A. Bush concerning Hadamard matrices. *Bulletin of the Australian Mathematical Society*, 1972, no. 6, pp. 321–326.
11. **Ito N., Longyear J.** Hadamard matrices of Bush-type. *Mathematical Journal of Okayama University*, 1985, no. 27, pp. 127–133.
12. **Janko Z., Kharaghani H., Tonchev V. D.** Bush-type Hadamard matrices and symmetric designs. *Journal of Combinatorial Designs*, 2001, no. 9, pp. 72–78.
13. **Golemac A., Vucicic T.** New (100; 45; 20) symmetric designs and Bush-type Hadamard matrices of order 100. *Discrete Mathematics*, 2002, vol. 245, iss. 1–3, pp. 263–272. doi:10.1016/S0012-365X(01)00309-0
14. **Балонин Ю. Н.** Программный комплекс MMatrix-2 и найденные им M-матрицы. *Вестник компьютер-*

ных и информационных технологий, 2013, № 10, с. 58–63.

15. Балонин Н. А., Сергеев М. Б. Матрица золотого сечения G_{10} . *Информационно-управляющие системы*, 2013, № 6, с. 2–5.

16. Сергеев А. М. Простые числа и симметрии квазиортогональных матриц Мерсенна. *Математические методы и модели в высокотехнологичном производстве: тез. докл. I Междунар. форума*, Санкт-Петербург, 10–11 ноября 2021 г. СПб., 2021, с. 14–15.

UDC 519.614

doi:10.31799/1684-8853-2024-1-2-8

EDN: DSXAAV

Matrices of the Hadamard family as slices of an orthogonal hyperobject at adjacent orders

N. A. Balonin^a, Dr. Sc., Tech., Professor, orcid.org/0000-0001-7338-4920, korbendfs@mail.ru

A. M. Sergeev^a, PhD, Associate Professor, orcid.org/0000-0002-4788-9869

M. B. Sergeev^a, Dr. Sc., Tech., Professor, orcid.org/0000-0002-3845-9277

^aSaint Petersburg State University of Aerospace Instrumentation, 67, B. Morskaya St., 190000, Saint-Petersburg, Russian Federation

Introduction: The integer formulation of the problem of finding Hadamard matrices that are extreme in terms of the determinant leaves in uncertainty the question of whether the iterations that usually search for the extremum end with integer matrices. From the point of view of the success the solvability of Hadamard's hypothesis about the existence of all such matrices, enumeration methods for finding them are not very effective in comparison with the methods of non-combinatorial mathematics. **Purpose:** To show the solvability of the problem of searching for the matrices of the Hadamard family through the slices of an orthogonal hyperobject on adjacent orders corresponding to a sequence of natural numbers t . **Results:** We have ascertained that since the matrices of the Hadamard family are defined by the invariants of lower-order matrices embedded in their structure, the hyperobject turns out to be a universal basis for their joint location. The discovery of the phenomenon of an orthogonal hyperobject has made it possible to reduce the step size in the orders of orthogonal matrices generated on its basis from $4t$ (for Hadamard matrices) to t . **Practical relevance:** Orthogonal matrices as the results of slices of an orthogonal hyperobject significantly expand the family of Hadamard matrices, which are of great practical importance for problems of orthogonal transformations of information.

Keywords – noise-resistant coding, Hadamard matrices, Cretan matrices, orthogonal hyperobject, Procrustes algorithm, matrix symmetries.

For citation: Balonin N. A., Sergeev A. M., Sergeev M. B. Matrices of the Hadamard family as slices of an orthogonal hyperobject at adjacent orders. *Информационно-управляющие системы* [Information and Control Systems], 2024, no. 1, pp. 2–8 (In Russian). doi:10.31799/1684-8853-2024-1-2-8, EDN: DSXAAV

Financial support

The work was carried out with financial support from the Ministry of Science and Higher Education of the Russian Federation, agreement No. FSRF-2023-0003 “Fundamentals of structures of noise-protected spacecraft systems communication and satellite communications, relative navigation gation, technical vision and aerospace monitoring”.

References

- Shalom E. La conjecture de Hadamard (I) – Images des Mathématiques. CNRS, 2012. Available at: images.math.cnrs.fr/La-conjecture-de-Hadamard-I.html (accessed 17 December 2023).
- Leighton R. The surface of Mars. *Uspekhi fizicheskikh nauk*, 1971, vol. 103, iss. 4, pp. 755–768 (In Russian).
- Jennifer S., Yamada M. *Hadamard Matrices: Constructions using Number Theory and Linear Algebra*. Wiley, 2020. 384 p.
- Horadam K. J. *Hadamard Matrices and their Applications*. Princeton University Press, 2007. 263 p.
- Wang R. *Introduction to Orthogonal Transforms with Applications in Data Processing and Analysis*. Cambridge University Press, 2010. 504 p.
- Vostrikov A. A., Balonin Y. N. Hadamard – Mersenne matrices as a basis of orthogonal transformation for video masking encoding. *Journal of Instrument Engineering*, 2014, vol. 57, no. 1, pp. 15–19 (In Russian).
- Grigoriev E. K. Study of correlation properties of new code sequences based on persymmetric quasi-orthogonal circulant. *Proceedings of Telecommunication Universities*, 2022, vol. 8, no. 2, pp. 83–90 (In Russian). doi:10.31854/1813-324X-2022-8-2-83-90
- Balonin N. A., Seberry J., Sergeev M. B. Solvable and unsolvable problems. Using Procrustes analysis algorithm for obtaining a family of Hadamard matrices. *Информационно-управляющие системы* [Information and Control Systems], 2023, no. 1, pp. 2–16 (In Russian). doi:10.31799/1684-8853-2023-1-2-16
- Balonin N. A., Sergeev M. B., Suzdal V. S. Dynamic generators of the quasiorthogonal Hadamard matrix family. *SPIIRAS Proceedings*, 2017, vol. 5 (54), pp. 224–243 (In Russian). doi:10.15622/sp.54.10
- Wallis W. D. On a problem of K. A. Bush concerning Hadamard matrices. *Bulletin of the Australian Mathematical Society*, 1972, no. 6, pp. 321–326.
- Ito N., Longyear J. Hadamard matrices of Bush-type. *Mathematical Journal of Okayama University*, 1985, no. 27, pp. 127–133.
- Janko Z., Kharaghani H., Tonchev V. D. Bush-type Hadamard matrices and symmetric designs. *Journal of Combinatorial Designs*, 2001, no. 9, pp. 72–78.
- Golemac A., Vucicic T. New (100; 45; 20) symmetric designs and Bush-type Hadamard matrices of order 100. *Discrete Mathematics*, 2002, vol. 245, iss. 1–3, pp. 263–272. doi:10.1016/S0012-365X(01)00309-0
- Balonin Yu. N. The software complex Mmatrix-2 and searched minimax matrices. *Herald of Computer and Information Technologies*, 2013, no. 10, pp. 58–63 (In Russian).
- Balonin N. A., Sergeev M. B. Matrix of golden ratio G_{10} . *Информационно-управляющие системы* [Information and Control Systems], 2013, no. 6, pp. 2–5 (In Russian).
- Sergeev A. M. Prime numbers and symmetries of quasi-orthogonal Mersenne matrices. *Trudy I Mezhdunarodnogo foruma “Matematicheskie metody i modeli v vysokotekhnologichnom proizvodstve”* [Proc. 1st Int. Symp. “Mathematical methods and models in high-tech production”]. Saint-Petersburg, 2021, pp. 14–15 (In Russian).



Определение оптимального набора метрик подобия графов в задачах распознавания топологий техногенных космических объектов

Н. В. Груздев^а, канд. воен. наук, доцент, orcid.org/0009-0000-6125-1362, NikGruzdev@rambler.ru

Ф. Л. Шуваев^а, канд. техн. наук, начальник лаборатории, orcid.org/0000-0001-7502-9455

^аВоенно-космическая академия им. А. Ф. Можайского, ул. Ждановская, 13, Санкт-Петербург, 197198, РФ

Введение: в условиях техногенного засорения околоземного космического пространства актуальной остается задача анализа результатов наблюдений за техногенными космическими объектами в целях выявления однотипных по топологии групп объектов. Для ее решения предлагается использовать инструментарий теории графов и теории распознавания для оценивания топологий техногенных космических объектов различного типа. **Цель:** выполнить сравнительный анализ метрик подобия графов, заключающийся в поиске оптимальной метрики в рамках показателей качества распознавания техногенных космических объектов. **Результаты:** проведенные исследования показали, что существует три основных подхода к расчету метрик подобия графов. Каждый из подходов основан на вычислении вектора параметров, характеризующих граф с различных сторон. Разработаны метрики, позволяющие различать группы техногенных космических объектов, представленных в виде графов. Вычислительный эксперимент показал, что оптимальный по критерию качества кластеризации состав признакового пространства отличается для различных типов графовых моделей. Это свойство играет важную роль при решении задач распознавания топологии техногенных космических объектов на новом качественном уровне. Применяя предложенные методы сравнительного анализа метрик подобия графов, возможно выбрать наилучшую метрику для распознавания топологии техногенных космических объектов. **Практическая значимость:** использование предлагаемых методов анализа метрик подобия графов позволит оценить изменения в группах однотипных техногенных космических объектов. Предложенные методы могут использоваться при решении задач контроля и каталогизации техногенных космических объектов.

Ключевые слова – техногенные космические объекты, граф, метрики подобия графов, топология, мера сходства, кластеризация.

Для цитирования: Груздев Н. В., Шуваев Ф. Л. Определение оптимального набора метрик подобия графов в задачах распознавания топологий техногенных космических объектов. *Информационно-управляющие системы*, 2024, № 1, с. 9–19. doi:10.31799/1684-8853-2024-1-9-19, EDN: OWCDGM

For citation: Gruzdev N. V., Shuvaev F. L. Determination of the optimal set of graph similarity metrics in problems of recognition of topologies of technogenic space objects. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 9–19 (In Russian). doi:10.31799/1684-8853-2024-1-9-19, EDN: OWCDGM

Введение

В настоящее время активно увеличивается число областей, где находит практическое применение теория графов для исследования сложных объектов или групп объектов, связанных в определенную структуру.

Теория графов интересна тем, что позволяет наглядно отображать и исследовать различные природные, техногенные и социальные процессы. Она позволяет представить сложные объекты исследования (сети связи, сети электроснабжения, космические объекты, атомы молекул, социальные сети) в виде графа (G) – совокупности вершин (V , т. е. простых объектов) и ребер (E , связей между ними). Типы взаимосвязей, образующих граф, неслучайны. Они отражают лежащие в основе сложных сетевых объектов процессы, которые можно исследовать с помощью различных разделов теории графов. Основные направления анализа сетей включают:

- визуализацию и формализацию сетей с использованием аппарата теории графов;
- оценивание структуры сети в целом, а также оценивание параметров структурных элементов – отдельных подсетей и узлов, связей между ними;
- создание математических и статистических моделей сетевых структур и сетевой динамики.

Техногенные космические объекты (отделяемые части ракет космического назначения, разгонные блоки, космические аппараты) представляются в виде графа. В работе [1] предложено решающее правило для выбора наиболее опасного (с точки зрения вероятного столкновения) техногенного объекта из множества наблюдаемых по результатам измерений их частных признаков. В целях выявления изменений, происходящих в группе наблюдаемых опасных техногенных космических объектов, возникает задача анализа сетевой структуры наблюдаемой группы объ-

ектов. Изменения в сетевой структуре техногенных космических объектов, проявляющиеся либо в результате визуализации, либо в результате структурного анализа, зачастую не видны человеку, но легко выявляются машинным зрением, и интерпретация полученных результатов дает понимание основных закономерностей, имеющих место в наблюдаемой системе, и причин их возникновения [2–4].

Авторами [5] выделяется два типичных варианта трансформации динамических графов [6, 7]. По первому варианту со временем изменяется число вершин, что соответствует изменению структуры исследуемой сети, что характерно для развивающихся, эволюционирующих или деградирующих сетей. По второму варианту число вершин графа неизменно, однако изменяется характер связей между ними, что характерно для устоявшихся систем, для систем с ограниченным числом элементов. Наибольший интерес в прикладном смысле имеет второй вариант, отвечающий таким направлениям, как исследование вариативности социальных связей в ограниченном коллективе, исследование процессов самоорганизации робототехнических систем с ограниченным числом объектов, исследование космических объектов и др. При таком варианте анализируется стационарная система (стационарная в смысле фиксированного числа вершин графа), в которой в равные интервалы времени ребра между вершинами меняются, тем самым изменяя топологию графа.

Исследование таких графовых структур состоит в выявлении условий образования или исчезновения ребер и распознавании тенденций трансформации связей между вершинами. В этом и заключается актуальность задачи распознавания графов по их топологической структуре. Важнейшим этапом задачи распознавания является определение оптимального признакового пространства; применительно к данному исследованию признаковым пространством являются метрики топологической близости графов.

С учетом ограниченности числа вершин задача упорядочивания графов по их топологической структуре является конечномерной. Однако с ростом числа вершин число топологических структур растет катастрофически [8], что требует для их перечисления огромных вычислительных мощностей [9]. В настоящее время известен целый ряд подходов к решению задачи упорядочивания графов по их топологической структуре на основе сокращения размерности параметрического описания графовой структуры с использованием различных метрик [10–25].

Наличие различных методов и метрик для оценивания топологической близости графов порождает задачу их сравнительного анализа

с целью выбрать оптимальное сочетание по критерию «качество кластеризации» в конкретных условиях. Решению этой задачи посвящено данное исследование.

Основные этапы сравнительного анализа

В основе сравнительного анализа метрик топологической близости графов лежат следующие базовые положения:

1) задача кластеризации графов различной природы может быть решена только в условиях различимости графовых структур;

2) для порождения различных по природе возникновения графовых структур возможно использовать модели случайных графов различных классов [11–13, 25–27];

3) в исследовании используются метрики топологической близости, основанные на расчете триадного вектора, интегральных характеристиках графов и топологических индексах. Все метрики широко освещены в научной литературе и опубликованы в работах последнего времени [14–25];

4) для метрик, в состав которых входят неортогональные компоненты, необходимо провести предварительный анализ информативности компонент для сокращения признакового пространства;

5) чтобы оценить результаты анализа информативности компонент, необходимо сравнить их с реальными показателями, а для этого требуется перебрать все возможные комбинации признаков и рассчитать качество кластеризации для них.

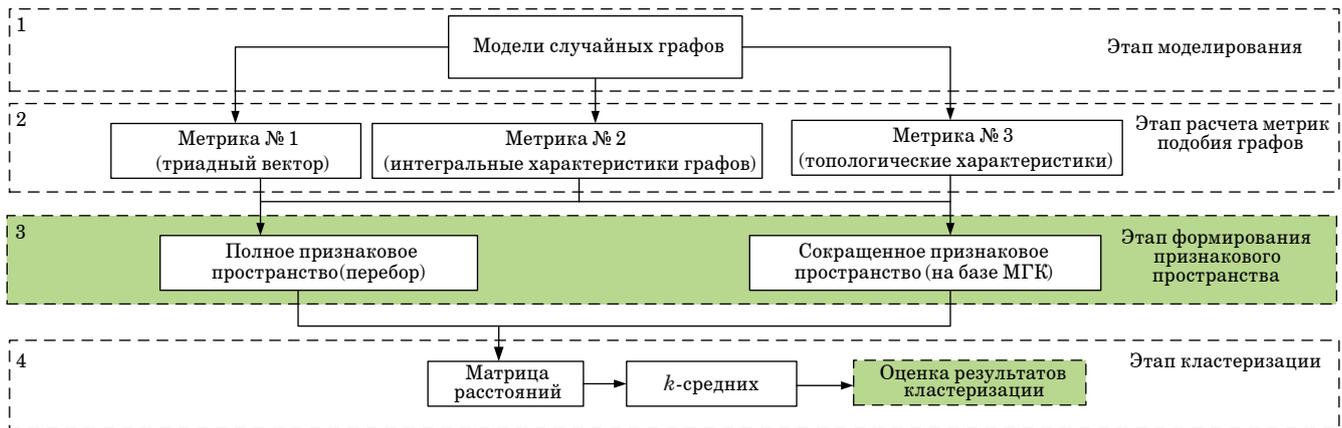
Структурная схема проводимого в рамках исследования сравнительного анализа метрик подобия графов изображена на рис. 1. Каждый из четырех основных этапов подразделяется на вспомогательные подэтапы.

Этап моделирования

Этап моделирования предназначен для формирования матриц смежности случайных графов. В настоящее время в науке наиболее активно применяемыми считаются модели случайного графа Эрдеша – Реньи (ЭР), модель Уоттса – Строгатца (УС) и модель Барабаши – Альберта (БА) [11–13, 25, 26]. Модель УС является модификацией модели ЭР, поэтому в дальнейшем при проведении эксперимента ограничимся моделями БА и ЭР. Алгоритм построения моделей подробно описан в работе [25].

Выбор и обоснование параметров моделей.

При формировании исходных данных для исследования различных метрик схожести графов



■ **Рис. 1.** Структурная схема исследования
 ■ **Fig. 1.** Block diagram of the study

удобно использовать модели случайных графов, порождающие непересекающиеся классы графов для распознавания. Для этого необходимо рассчитать вероятность изоморфизма графов $P_{из}$, порождаемых различными математическими моделями. Логично предположить, что вероятность появления изоморфных друг другу графов $P_{из}$, порождаемых моделями разных классов, уменьшается при увеличении числа вершин.

В рамках этого предположения сформированы по 10 000 реализаций случайных графов для каждой из рассматриваемых моделей (табл. 1) и проведено попарное сравнение графов на изоморфизм внутри каждого класса и между классами.

При этом оценка вероятности появления изоморфных графов рассчитывается как $P_{из} = \frac{n_{из}}{n_{общ}}$, где $n_{из}$ – число пар изоморфных графов; $n_{общ}$ – общее число пар графов. Для 500 графов получим $n_{общ} = 124\ 750$. Полученные результаты свидетельствуют, что для графов

с числом вершин 12 и более величина $P_{из} \approx 0$ при значении доверительной вероятности на уровне 0,95. На этом основании выберем число вершин для формирования случайных графов не менее 12, например 60. Чтобы результаты эксперимента были адекватными, параметр «число ребер» моделей подобран в равные интервалы. Для этого измерены граничные значения числа ребер для моделей БА.

Вычислительный эксперимент был разделен на два этапа: 1-й этап – проведение кластеризации для моделей БА и ЭР; 2-й этап – проведение кластеризации для двух моделей БА. Таким образом, на каждом этапе эксперимента проводилась кластеризация для двух классов. На каждом этапе формировалось по 10 000 графов каждого класса, при этом на этапе 1 параметры модели 1 « p_1, p_2, p_3 » задавались случайно с равномерным распределением в интервале от 0,1 до 0,9 с шагом 0,1, а параметр модели 2 «число ребер» задавался случайно в интервале от 100 до 200.

На этапе 2 параметр модели 3 « $p_2 = 0,1$ » был фиксирован, параметры « p_3 » и « p_4 » задавались случайно с равномерным распределением в интервале от 0,1 до 0,9 с шагом 0,1. Параметр модели 4 « $p_2 = 0,9$ » был фиксирован, « p_3 » и « p_4 » задавались аналогично модели 3.

Модели ЭР подобны социальным структурам с низкой централизацией, отсутствием узлов с высокой центральностью, а модели БА, напротив, формируют графы с низкой централизацией и строгой иерархической структурой, тем самым они подобны социальным структурам с высокой организацией. Изучение возможности распознавания сетей с низкой и высокой централизацией осуществляется на этапе 1, а распознавание сетей с высокой централизацией, но разными формами ее порождения, – на этапе 2.

■ **Таблица 1.** Параметры моделей графов
 ■ **Table 1.** Parameters of graph models

Этап	Номер модели	Тип модели	Число вершин	Число ребер	Дополнительные параметры
1	1	БА	60	76:117	$p_{2,3} = (0,1:0,9)$ с шагом 0,1
	2	ЭР	60	76:117	–
2	3	БА	60	76:117	$p_2 = 0,1$ $p_3 = (0,1:0,9)$ $p_4 = (0,1:0,9)$
	4	БА	60	59:102	$p_2 = 0,1$ $p_3 = (0,1:0,9)$ $p_4 = (0,1:0,9)$

Этап расчета метрик подобия графов

На данном этапе рассчитываются метрики подобия, проявляющие различие или близость топологической структуры графов. Метрики разделены на три группы.

Метрика № 1. Триадный вектор.

В основе метрики № 1 лежит утверждение, что минимально различимой структурой графа является диада: две вершины, между которыми либо есть, либо нет ребра изучаемого типа, т. е. наличие или отсутствие связи между вершинами. Анализ публикаций в области теории графов за последние пять лет показал, что наиболее предпочтительной минимальной единицей в социальной группе является триада [14–17]. Триада – это граф, состоящий из трех вершин. Комбинации ребер между вершинами в триаде определяются 16 возможными вариантами построения, количество классов таких комбинаций называется триадным вектором.

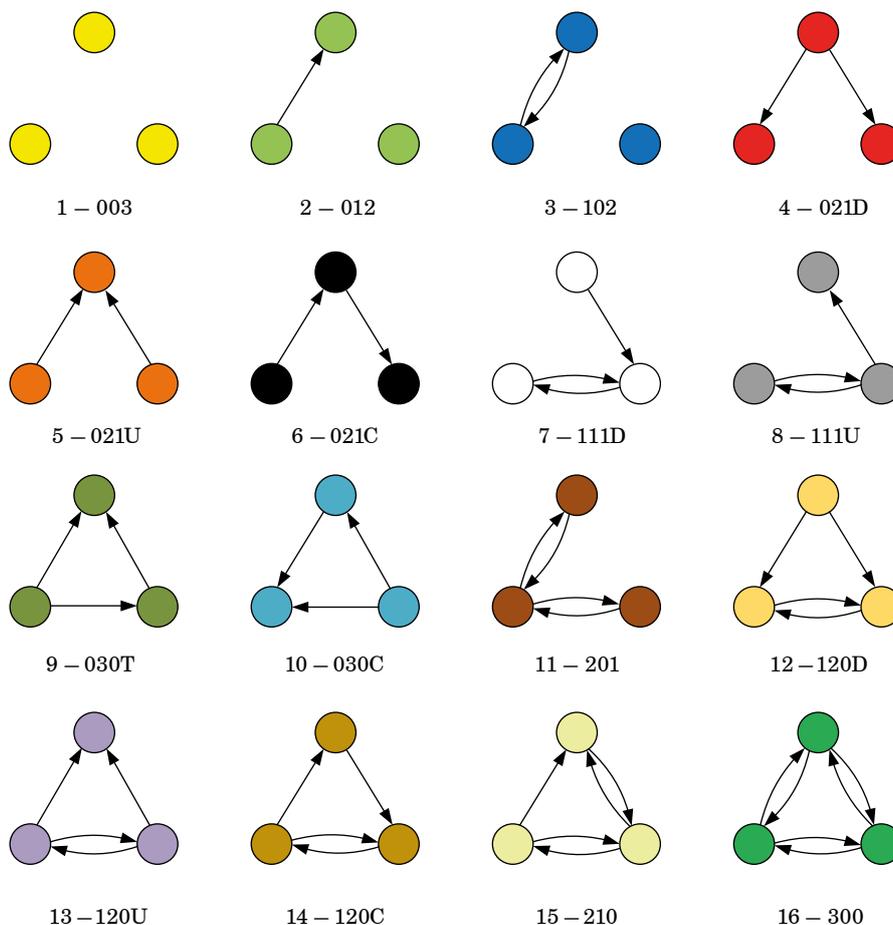
Рассчитав триадные векторы для графов, исследователь получает метрику или пространство признаков, на основе которого рассчитывается

расстояние между графами и определяется степень их подобия. Таким образом, триадный вектор может быть использован как метрика расстояния между графами. На рис. 2 [14] показаны триады и соответствующие обозначения.

Для различения комбинаций употребляются символы латинского алфавита, например: «D» – вниз (асимметричная связь или связи направлены вниз); «U» – вверх (асимметричная связь или связи направлены вверх); «C» – триада циклическая; «T» – триада транзитивная [14–17].

Метрика № 2. Интегральные характеристики графов.

В теории графов имеются различные характеристики, описывающие те или иные свойства графов, среди них основные: среднее расстояние пути (СРс), плотность графа (ПГ), ассортативность (АС), централизация по степени (ЦС), централизация по близости (ЦБ), централизация по посредничеству (ЦП), централизация по собственному вектору (СВЦ), централизация Кляйнберга (КЦ), централизация по авторитетности (АЦ) [10, 22–25]. Рассчитав для каждого



■ **Рис. 2.** Комбинации триад [14]
 ■ **Fig. 2.** Combinations of triads [14]

графа набор значений таких параметров, возможно перейти к матрице расстояний между ними, т. е. представить граф в признаковом пространстве, описанном образами – интегральными характеристиками графов.

Метрика № 3. Топологические индексы.

Топологический индекс – некоторое обычно числовое значение или упорядоченный набор значений, характеризующих структуру графа. Широкое применение топологические индексы получили в хромометрии для исследования химических свойств веществ. Для исследования были выбраны три наиболее известных топологических индекса: Винера (Ви), сумм строк (ССт), эффективной сложности (ЭС) [19–21].

Полученные значения параметров y_{ij} помещаются в матрицу данных, где i – номер метрики; j – номер графа. Таким образом, ячейки матрицы заполняют N метрик для n графов:

$$Y_{[N,n]} = \|y_{ij}\|_N^n.$$

Этап формирования признакового пространства

В нашем исследовании рассматривается два варианта формирования признакового пространства: 1) полное признаковое пространство, при котором перебираются все комбинации признаков и для каждой оценивается качество кластеризации; 2) сокращенное признаковое пространство, причем сокращение пространства осуществляется за счет выявления наиболее информативных признаков на основе компонентного анализа.

Компонентный анализ.

Компонентный анализ в рамках метода главных компонент (МГК; Principal Component Analysis – PCA) представляет собой совокупность статистических приемов обработки данных, которые позволяют сконцентрировать содержащуюся в исходном массиве данных информацию за счет перехода к меньшему числу наиболее информативных факторов – главных компонент (ГК) [23].

Для каждого из исследуемых графов осуществляется расчет вклада различных характеристик графов в пространстве ГК. Для расчета удельного вклада каждой интегральной характеристики используется следующее выражение [23]:

$$Con_j = \frac{f_1(y_j)f_2(y_j)}{\sum_{k=1}^I f_1(y_k)f_2(y_k)}, [j = 1(1)n],$$

где $f_1(y_j)$ и $f_2(y_j)$ – значение вклада j -го признака в ГК1 и ГК2.

Таким образом, значение удельного вклада Con (от англ. «contribution») является произведением

вклада в ГК1 и ГК2 j -го признака графа, нормированного на сумму вкладов остальных мер в ГК1 и ГК2. На основе удельного вклада возможно выбирать наиболее информативные признаки, позволяющие сокращать признаковое пространство и проводить кластеризацию с наивысшим качеством.

Этап кластеризации

Процедура кластеризации в исследовании используется для оценивания разделяющей способности сравниваемых метрик подобия графов. Учитывая, что цель исследования состоит в сравнении различных метрик подобия графов, для решения задачи кластеризации графов, порождаемых различными исследуемыми моделями, можно использовать алгоритм кластеризации с известным числом классов по методу k -средних [28].

Метод k -средних, один из самых распространенных методов кластеризации, был предложен в 1950-х годах математиком Гуго Штейнгаузом. Суть метода заключается в минимизации S – суммарного квадратичного отклонения координат элементов кластеров от центров этих кластеров – на основе итеративной процедуры пересчета координат центров кластеров и состава кластеров [28].

Этап оценки результатов кластеризации

Для оценки результатов кластеризации был выбран коэффициент Фоулкса – Мэллова (КФМ) [25, 29] – мера сходства между двумя результатами кластеризации (в настоящем исследовании между истинными значениями классов $A1$ и значениями классов $A2$, полученными в результате кластеризации). Коэффициент изменяется в пределах $[0; 1]$. Чем его значение выше, тем выше качество кластеризации [23].

Результаты экспериментальных исследований

Анализ методом ГК метрик подобия графов показал, что в метрике № 2 коллинеарными являются характеристики АЦ и КЦ, поэтому исходное количество признаков сокращено за счет удаления КЦ. При вычислении метрики № 1 было установлено, что триады с шестой по 16 в рассматриваемых моделях графов отсутствуют, поэтому в метрике № 1 количество признаков сокращено с 16 до пяти. Таким образом, матрица наблюдений приобретает вид $Y_{[16,20000]}$. Итоговое число признаков: метрика № 1 – 5, метрика № 2 – 8, метрика № 3 – 3, итого 16.

Качество кластеризации в ходе эксперимента рассчитывалось для комбинаций из 1:16 признаков с целью выявить комбинацию, позволяющую разделить смеси моделей наилучшим образом. При этом наилучшей считается при-

знак или комбинация признаков, обладающая самым высоким значением КФМ. Вычисления осуществлялись на сервере HPProliantDL380, на базе двух процессоров INTEL Xeon silver 4214. Моделирование осуществлялось средствами языка R, распараллеливание работы процессоров обеспечивалось библиотекой doParallel [30].

1-й этап (рис. 3, а, б). Корреляционная окружность представляет собой вариант визуализации результатов компонентного анализа. Радиус корреляционной окружности равен единице и интерпретирует суммарный вклад первой и второй компонент. Ближайшие к радиусу векторы признаков соответствуют наибольшему вкладу в первую и вторую компоненты. Чем ближе расположены друг к другу признаки (обозначены квадратом красной пунктирной линией на корреляционной окружности), тем больше у них совместный вклад в ГК1 и ГК2.

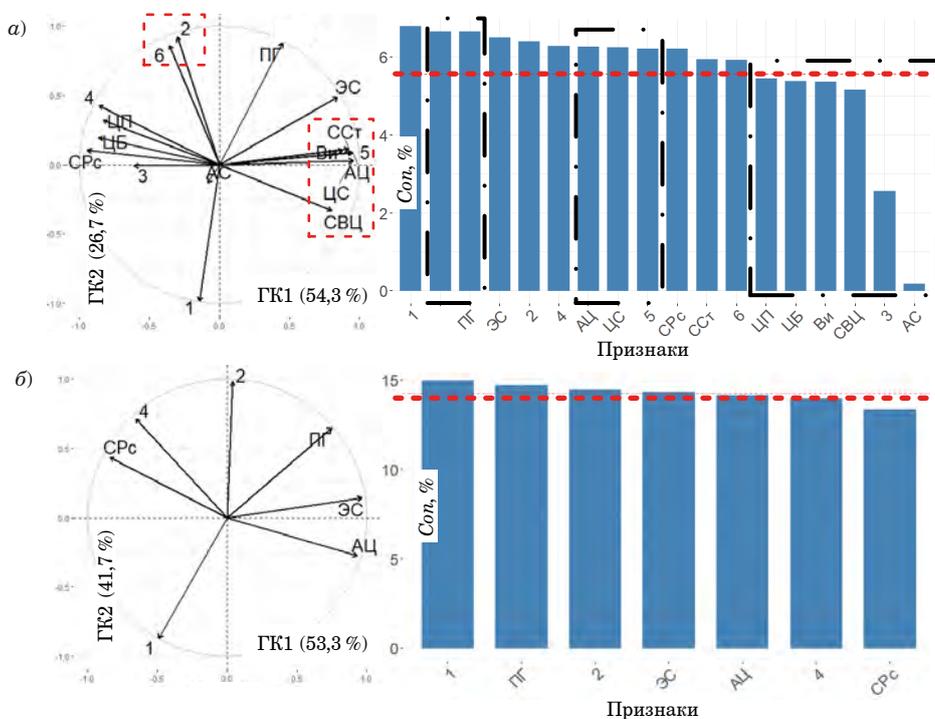
Красная пунктирная, проведенная через признаки, — это средний удельный вклад в ГК1 и ГК2. Рассчитывается как деление всего вклада (100 %) на количество признаков. В соответствии с методикой применения МГК признаковое пространство сокращается за счет удаления коллинеарных признаков, удаления признаков с *Con* ниже среднего значения (выделены на признаках рис. 3, а черной штрихпунктирной линией) и перколяции (т. е. удаления из группы одно-

типных признаков тех, у которых ниже значение *Con*), сходных по степени вклада признаков.

На рис. 3, б представлено сокращенное в соответствии с этой методикой до семи признаков пространство. Корреляционная окружность рис. 3, б показывает, что суммарный вклад в ГК1 и ГК2 вырос до 95 % (41,7 + 53,3) по сравнению с 81 % (54,3 + 26,7) на корреляционной окружности рис. 3, а. Это позитивное наблюдение подчеркивает правильность выбранных шагов по сокращению признаков.

Результаты сравнения качества кластеризации с использованием признакового пространства, выбранного на основе компонентного анализа и метода перебора, представлены в табл. 2. Обозначение столбцов таблицы: 1 — количество признаков; 2 — тип признакового пространства; 3 — количество комбинаций признаков; 4 — количество комбинаций с наилучшим КФМ; 5 — наилучший КФМ; 6 — наихудший КФМ; 7 — средний КФМ; 8 — лучшая по МГК комбинация; 9 — КФМ лучшей по МГК комбинации.

Анализ результатов, представленных в табл. 2, сделал возможным выявить характерную особенность, заключающуюся в том, что на этапе 1 при числе признаков $N = \{2:7\}$ при полном переборе КФМ = 1. Для $N = 2$ это комбинации ЦС-ЭС и ЦП-ЭС, при $N = 7$ это комбинация ПГ-АС-ЦС-СВЦ-ЦБ-ЦП-ЭС. При $N = 3, 4, 5, 6$ признаки не выходят



■ **Рис. 3.** Результаты применения МГК на этапе 1 до (а) и после (б) сокращения признакового пространства: слева — корреляционная окружность; справа — ранжированные по значению удельного вклада признаки
 ■ **Fig. 3.** The results of the use of PCA at stage 1 before (a) and after (b) the reduction of the feature space: left — correlation circle; on right — features ranked by the value of the specific contribution

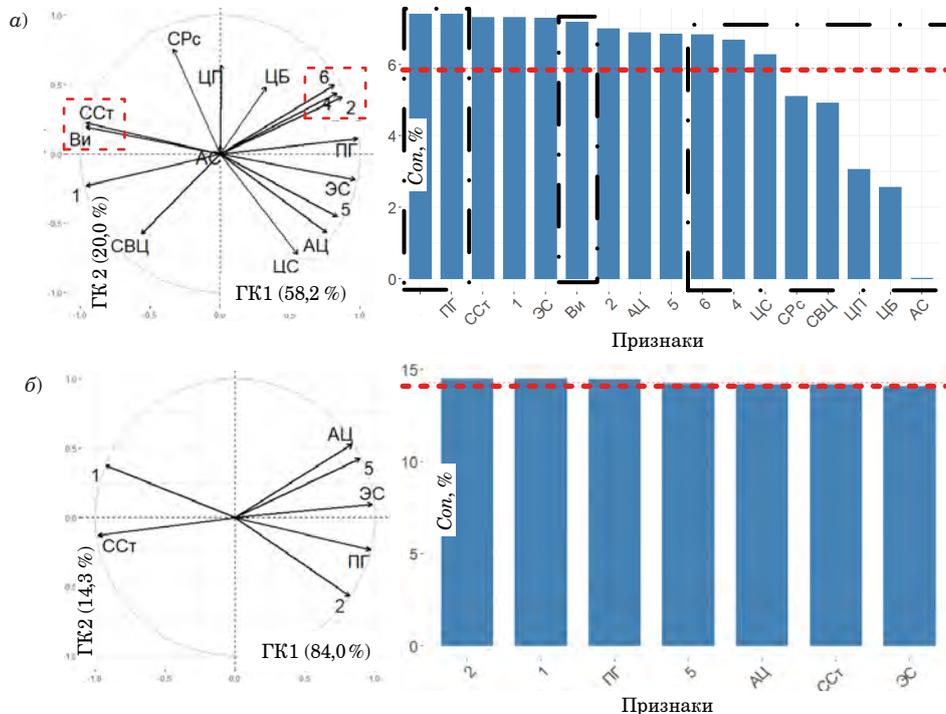
■ **Таблица 2.** Результаты вычислительного эксперимента на этапе 1
 ■ **Table 2.** Results of the computational experiment at stage 1

1	2	3	4	5	6	7	8	9
1	Сокращенное	7	1	0,95	0,50	0,73	1	0,56
	Полное	16	1	0,95	0,50	0,77		
2	Сокращенное	21	2	0,95	0,49	0,70	1-ПГ	0,58
	Полное	120	2	1	0,49	0,78		
3	Сокращенное	35	1	0,95	0,49	0,63	1-ПГ-2	0,56
	Полное	560	9	1	0,49	0,77		
4	Сокращенное	35	4	0,93	0,49	0,58	1-ПГ-2-5	0,56
	Полное	1820	15	1	0,49	0,76		
5	Сокращенное	21	1	0,93	0,49	0,54	1-ПГ-2-5-ЭС	0,61
	Полное	4368	14	1	0,49	0,75		
6	Сокращенное	7	1	0,55	0,49	0,51	1-ПГ-2-5-ЭС-4	0,55
	Полное	8008	6	1	0,49	0,75		
7	Сокращенное	1	1	0,49	0,49	0,49	1-ПГ-2-5-ЭС-4-СРс	0,49
	Полное	11 440	1	1	0,49	0,75		

из границ множества ПГ-АС-ЦС-СВЦ-ЦБ-ЦП-ЭС. Видны граничные пределы по распознаванию графов, выраженные в КФМ: нижний – 0,49; верхний – 1. Из столбцов 8 и 9 видно, что комбинации, определенные по МГК, не являются оптимальны-

ми по критерию КФМ. Особенностью является также и то, что увеличение размерности признакового пространства не приводит к повышению КФМ.

2-й этап (рис. 4, а, б). На корреляционной окружности рис. 4, а видно, что тенденции по



■ **Рис. 4.** Результаты применения МГК на этапе 2 до (а) и после (б) сокращения признакового пространства: слева – корреляционная окружность; справа – ранжированные по значению удельного вклада признаки
 ■ **Fig. 4.** The results of the use of PCA at stage 2 before (a) and after (b) the reduction of the feature space: left – correlation circle; on right – features ranked by the value of the specific contribution

■ **Таблица 3.** Результаты вычислительного эксперимента на этапе 2

■ **Table 3.** Results of the computational experiment at stage 2

1	2	3	4	5	6	7	8	9
1	Сокращенное	7	1	0,90	0,57	0,77	1	0,88
	Полное	16	1	0,90	0,50	0,68		
2	Сокращенное	21	1	0,89	0,57	0,79	1-ПГ	0,88
	Полное	120	1	0,90	0,49	0,72		
3	Сокращенное	35	4	0,89	0,70	0,82	1-ПГ-2	0,88
	Полное	560	12	0,89	0,49	0,75		
4	Сокращенное	35	5	0,89	0,70	0,84	1-ПГ-2-ССТ	0,88
	Полное	1820	66	0,89	0,49	0,77		
5	Сокращенное	21	4	0,89	0,71	0,86	1-ПГ-2-ССТ-ЭС	0,88
	Полное	4368	221	0,89	0,49	0,79		
6	Сокращенное	7	1	0,89	0,81	0,87	1-ПГ-2-ССТ-ЭС-5	0,88
	Полное	8008	494	0,89	0,49	0,80		
7	Сокращенное	1	1	0,88	0,88	0,88	1-ПГ-2-ССТ-ЭС-5-ЦС	0,88
	Полное	11 440	789	0,89	0,51	0,80		

группированию признаков схожи с рис. 3, а лишь отчасти. Так, схожи по-прежнему Ви и ССт, триады 6 и 2. Удельный вклад ниже среднего также имеют признаки ЦБ, СВЦ, ЦП и АС.

Признаковое пространство на этапе 2 сокращено аналогично этапу 1 до семи признаков (см. рис. 4, б). На корреляционной окружности рис. 4, б видно, что суммарный вклад в ГК1 и ГК2 вырос до 98,3 % (84,0 + 14,3), по сравнению с 78 % (20,0 + 58,2) на корреляционной окружности рис. 4, а.

Результаты вычислительного эксперимента для этапа 2 приведены в табл. 3.

Минимальный КФМ на этапе 2 составляет 0,49, как и на этапе 1, максимальный – 0,90. Комбинации признаков, отобранные на основе МГК, имеют стабильное значение КФМ = 0,88. В результате перебора установлено, что на этапе 2 наилучшим признаком является признак ПГ и комбинация ПГ-ЦБ с КФМ = 0,90.

Заключение

В ходе проведенного сравнительного анализа получены убедительные результаты, позволяющие выбирать наилучшую метрику для распознавания топологии техногенных космических объектов. Определены требования к числу вершин случайных графов, формируемых по моделям ЭР и БА, обеспечивающие близкую к нулевой вероятность изоморфизма порождаемых графов, что необходимо для обеспечения условия непересечения классов графов для распознавания. Методом ГК выявлена коллинеарность таких интегральных характери-

стик графов, как КЦ и АЦ, применительно к исследуемым моделям случайных графов.

Вычислительный эксперимент показал, что оптимальный по критерию качества кластеризации состав признакового пространства разный для различных типов графовых моделей. На этапе 1 исследовались модели различной природы – с низкой и высокой централизацией, но с равным количеством ребер. Проведенный эксперимент показал, что признак «плотность» графа, являющийся интегральным от количества ребер, в таких условиях обладает низкими разделяющими свойствами. А показатели централизации «центральность по степени и по близости», напротив, – высокими. При этом наилучшими признаками являются АС-ЦС-СВЦ-ЦБ-ЦП-ЭС-ПГ, причем оптимальными по размеру и качеству кластеризации являются комбинации ЦС-ЭС и ЦП-ЭС.

При проведении эксперимента на этапе 2 сравнение признаков, полученных от графовых моделей со схожей природой централизации, выявило наилучшие признаки ПГ и ЦБ, причем использование одного признака ПГ дает такое же качество кластеризации по КФМ, как и совместно с ЦБ. При распознавании моделей БА признаковое пространство может быть сокращено до одного признака.

Таким образом, разработанные методы анализа метрик подобия графов позволят на новом качественном уровне решать задачи выявления изменений, происходящих в группе наблюдаемых опасных техногенных космических объектов, представляющих опасность для функционирующих орбитальных средств.

Литература

1. Арсеньев В. Н., Ядренкин А. А., Слатова Е. В. Принятие решения о наиболее опасном техногенном объекте космическим аппаратом мониторинга околоземного космического пространства. *Информационно-управляющие системы*, 2023, № 4, с. 26–34. doi:10.31799/1684-8853-2023-4-26-34, EDN: ВНХТФ
2. Шевченко Д. Н., Литвин А. Ю., Федянин М. А. Имитационное моделирование графа состояний в задачах анализа надежности технических систем. *ПФМТ*, 2018, № 3(36), с. 101–104.
3. Chen P.-Y., Choudhury S., Hero A. Multi-centrality graph spectral decompositions and their application to cyber intrusion detection. *IEEE Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, China, 2016, 20–25 March. IEEE, 2016. doi:10.1109/ICASSP.2016.7472539
4. Newman M. E. J. *Networks an Introduction*. N.Y., Oxford University Press Inc., 2010. 1042 p.
5. Trivedi R., Farajtabar M., Biswal P., Zha H. DyREP: Learning representations over dynamic graphs. *Proc. of the 7th Intern. Conf. on Learning Representations (ICLR 2019)*, 2019, May 6–9, pp. 1–25.
6. Pareja A., Domeniconi G., Chen J., Ma T., Suzumura T., Kanezashi H., Kaler T., Schardl T., Leiserson Ch. EvolveGCN: Evolving graph convolutional networks for dynamic graphs. *The Thirty-Fourth AAAI Conf. on Artificial Intelligence (AAAI-20)*, 2020, pp. 5363–5370. doi:doi.org/10.1609/aaai.v34i04.5984
7. Khan A., Bhowmick S., Bonchi F. Summarizing static and dynamic big graphs. *Proc. of the VLDB Endowment*, 2017, vol. 10, iss. 12, pp. 1981–1984. doi:doi.org/10.14778/3137765.3137825
8. Cai J.-Y., Furer M., Immerman N. An optimal lower bound on the number of variables for graph identification. *Combinatorica*, 1992, vol. 12, pp. 389–410. doi:doi.org/10.1007/BF01305232
9. Neuen D., Schweitzer P. Benchmark graphs for practical graph isomorphism. *25th Annual European Symp. on Algorithms (ESA 2017). Leibniz Intern. Proc. in Informatics (LIPIcs)*, 2017, vol. 87, pp. 60:1–60:14. doi:10.4230/LIPIcs.ESA.2017.60
10. Шуваев Ф. Л., Татарка М. В. Анализ динамики мер центральности математических моделей случайных графов. *Научно-технический вестник информационных технологий, механики и оптики*, 2020, т. 20, № 2, с. 249–256. doi:10.17586/2226-1494-2020-20-2-249-256
11. Hartmann A., Mézard M. Distribution of diameters for Erdős — Rényi random graphs. *Phys. Rev.*, 2018, vol. 97, iss. 3. doi:10.1103 / PhysRevE.97.032128
12. Gibson H., Vickers P. Using adjacency matrices to lay out larger small-world networks. *Applied Soft Computing*, 2016, vol. 42, pp. 80–92.
13. Barabasi A. *Network Science*. Glasgow, Cambridge University Press, 2016. 453 p.
14. Zvereva O. M. Triad census usage for communication network analysis. *The 5th Intern. Conf. on Analysis of Images, Social Networks, and Texts*. Yekaterinburg, 2016, pp. 378–389. http://ceur-ws.org/Vol-1710/paper38.pdf (дата обращения: 15.08.2023).
15. Brunson J. C. Triadic analysis of affiliation networks. *Network Science*, 2015, no. 3 (4), pp. 480–508.
16. Татарка М. В., Шуваев Ф. Л. Метод распознавания топологий информационно-телекоммуникационных сетей на основе расчета триадного вектора. *Труды Военно-космической академии им. А. Ф. Можайского*, 2021, № 676, с. 73–84.
17. Faust K. A puzzle concerning triads in social networks: Graph constraints and the triad census. *Social Networks*, 2010, no. 32, pp. 221–233.
18. Faust K. Comparing social networks: size, density, and local structure. *Metodološki zvezki*, 2006, vol. 2, pp. 185–216.
19. Hayat S. Computing distance-based topological descriptors of complex chemical networks: New theoretical techniques. *Chemical Physics Letters*, 2017, vol. 688, pp. 51–58.
20. Mowshowitz A., Dehmer M. A symmetry index for graphs. *Symmetry: Culture and Science*, 2010, vol. 21, pp. 321–327.
21. Mueller L., Schutte M., Kugler K., Dehmer M. QuACN: an R package for analyzing complex biological networks quantitatively. *Bioinformatics*, 2011, vol. 27, pp. 140–141. doi:10.1093/bioinformatics/btq606
22. Bonchi F., De Francisci G., Riondato M. Centrality measures on big graphs: Exact, approximated, and distributed algorithms. *Proc. of the 25th Intern. Conf. “Companion on World Wide Web”*, 2016, pp. 1017–1020. doi:10.1145/2872518.2891063
23. Brandes U., Borgatti S., Freeman L. Maintaining the duality of closeness and betweenness centrality. *Social Networks*, 2016, vol. 44, pp. 153–159.
24. Mino A., Salehzadeh-Yazdi A., Razaghi-Moghadam Z., Hennig H., Wolkenhauer O. A systematic survey of centrality measures for protein-protein interaction networks. *BMC Systems Biology*, 2018, vol. 12, no. 1, pp. 80:1–80:17.
25. Еремеев И. Ю., Татарка М. В., Шуваев Ф. Л., Цыганов А. С. Анализ мер центральности узлов сетей на основе метода главных компонент. *Информатика и автоматизация*, 2020, т. 19, № 6, с. 1307–1331. doi:10.15622/ia.2020.19.6.7
26. Шуваев Ф. Л., Татарка М. В. Анализ математических моделей случайных графов, применяемых в имитационном моделировании информационно-коммуникационных сетей. *Вестник Санкт-Петербургского университета ГПС МЧС России*, 2020, № 2, с. 67–77.

27. Lê S., Josse J., Husson F. FactoMineR: A package for multivariate analysis. *Journal of Statistical Software*, 2008, vol. 25, iss. 1, pp. 1–18.

28. Bai L., Cheng X., Liang J., Shen H., Guo Y. Fast density clustering strategies based on the k-means algorithm. *Pattern Recognition*, 2017, vol. 71, pp. 375–386.

29. Depaolini M., Ciucci D., Calegari S., Dominoni M. External indices for rough clustering. *Lecture Notes in Computer Science*, 2018, vol. 11103.

30. Joy A., Korobova J. Bootstrapping clustered data in R using lmeresampler. arXiv: 2106.06568, 2021. doi:10.48550/arXiv.2106.06568

UDC 004.93

doi:10.31799/1684-8853-2024-1-9-19

EDN: OWCDGM

Determination of the optimal set of graph similarity metrics in problems of recognition of topologies of technogenic space objects

N. V. Gruzdev^a, PhD, Military, Associate Professor, orcid.org/0009-0000-6125-1362, NikGruzdev@rambler.ru

F. L. Shuvaev^a, PhD, Tech., Acting Head of Labs, orcid.org/0000-0001-7502-9455

^aA. F. Mozhaiskii Military Space Academy, 13, Zhdanovskaia Emb., 197198, Saint-Petersburg, Russian Federation

Introduction: The task of analyzing the results of observations of man-made space objects in order to identify groups of objects of the same topological type remains vital in the conditions of technogenic pollution of interplanetary environment. To solve this problem, it is proposed to use the tools of graph theory and recognition theory to evaluate the topologies of man-made space objects of various types. **Purpose:** To perform a comparative analysis of graph similarity metrics, which consists in finding the optimal metric within the framework of quality indicators for recognizing man-made space objects. **Results:** The conducted research has shown that there are three main approaches to the calculation of graph similarity metrics. Each of the approaches has its base on calculating the vector of parameters characterizing the graph from different sides. Developed metrics make it possible to distinguish between groups of man-made space objects represented in the form of graphs. A computational experiment has shown that the optimal composition of the feature space according to the clustering quality criterion is different for different types of graph models. This property plays an important role in solving problems of recognizing the topology of man-made space objects at a new qualitative level. Using the proposed methods of comparative analysis of graph similarity metrics, it is possible to choose the best metric for recognizing the topology of man-made space objects. **Practical relevance:** The use of the proposed methods for analyzing graph similarity metrics will allow us to assess changes in groups of similar man-made space objects. The proposed methods can be used in solving problems of control and cataloging of man-made space objects.

Keywords – technogenic space objects, graph, graph similarity metrics, topology, similarity measure, clustering.

For citation: Gruzdev N. V., Shuvaev F. L. Determination of the optimal set of graph similarity metrics in problems of recognition of topologies of technogenic space objects. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 9–19 (In Russian). doi:10.31799/1684-8853-2024-1-9-19, EDN: OWCDGM

References

1. Arseniev V. N., Yadrenkin A. A., Slatova E. V. Making a decision on the most dangerous man-made object by a spacecraft for monitoring near-Earth space. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2023, no. 4, pp. 26–34 (In Russian). doi:10.31799/1684-8853-2023-4-26-34, EDN: BHIXTF
2. Shevchenko D. N., Litvin A. Yu., Fedianin M. A. Reliability analysis of technical systems by simulation modeling of graph of states. *Problems of Physics, Mathematics and Technics*, 2018, no. 3(36), pp. 101–104 (In Russian).
3. Chen P.-Y., Choudhury S., Hero A. Multi-centrality graph spectral decompositions and their application to cyber intrusion detection. *IEEE Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, China, 2016. IEEE, 2016. doi:10.1109/ICASSP.2016.7472539
4. Newman M. E. J. *Networks an Introduction*. N.Y., Oxford University Press Inc., 2010. 1042 p.
5. Trivedi R., Farajtabar M., Biswal P., Zha H. DyREP: Learning representations over dynamic graphs. *Proc. of the 7th Intern. Conf. on Learning Representations (ICLR 2019)*, 2019, pp. 1–25.
6. Pareja A., Domeniconi G., Chen J., Ma T., Suzumura T., Kanezashi H., Kaler T., Schardl T., Leiserson Ch. EvolveGCN: Evolving graph convolutional networks for dynamic graphs. *The Thirty-Fourth AAAI Conf. on Artificial Intelligence (AAAI-20)*, 2020, pp. 5363–5370. doi:doi.org/10.1609/aaai.v34i04.5984
7. Khan A., Bhowmick S., Bonchi F. Summarizing static and dynamic big graphs. *Proc. of the VLDB Endowment*, 2017, vol. 10, iss. 12, pp. 1981–1984. doi:doi.org/10.14778/3137765.3137825
8. Cai J.-Y., Furer M., Immerman N. An optimal lower bound on the number of variables for graph identification. *Combinatorica*, 1992, vol. 12, pp. 389–410. doi:doi.org/10.1007/BF01305232
9. Neuen D., Schweitzer P. Benchmark graphs for practical graph isomorphism. *25th Annual European Symp. on Algorithms (ESA 2017). Leibniz Intern. Proc. in Informatics (LIPIcs)*, 2017, vol. 87, pp. 60:1–60:14. doi:10.4230/LIPIcs.ESA.2017.60
10. Shuvaev F. L., Tatarka M. V. Dynamics of centrality measures of random graph mathematical models. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2020, vol. 20, no. 2, pp. 249–256 (In Russian). doi:10.17586/2226-1494-2020-20-2-249-256
11. Hartmann A., Mézard M. Distribution of diameters for Erdős — Rényi random graphs. *Phys. Rev.*, 2018, vol. 97, iss. 3. doi:10.1103/PhysRevE.97.032128
12. Gibson H., Vickers P. Using adjacency matrices to lay out larger small-world networks. *Applied Soft Computing*, 2016, vol. 42, pp. 80–92.
13. Barabasi A. *Network Science*. Glasgow, Cambridge University Press, 2016. 453 p.
14. Zvereva O. M. Triad census usage for communication network analysis. *The 5th Intern. Conf. on Analysis of Images, Social Networks, and Texts. Yekaterinburg*, 2016, pp. 378–389. Available at: <http://ceur-ws.org/Vol-1710/paper38.pdf> (accessed 15 August 2023).
15. Brunson J. C. Triadic analysis of affiliation networks. *Network Science*, 2015, no. 3 (4), pp. 480–508.
16. Tatarka M. V., Shuvaev F. L. Method of recognition of topologies of information-telecommunication networks on the

- basis of calculation of triad census. *Proc. of the Mozhaisky Military Space Academy*, 2021, vol. 676, pp. 73–84 (In Russian).
17. Faust K. A puzzle concerning triads in social networks: Graph constraints and the triad census. *Social Networks*, 2010, no. 32, pp. 221–233.
 18. Faust K. Comparing social networks: size, density, and local structure. *Metodološki zvezki*, 2006, vol. 2, pp. 185–216.
 19. Hayat S. Computing distance-based topological descriptors of complex chemical networks: New theoretical techniques. *Chemical Physics Letters*, 2017, vol. 688, pp. 51–58.
 20. Mowshowitz A., Dehmer M. A symmetry index for graphs. *Symmetry: Culture and Science*, 2010, vol. 21, pp. 321–327.
 21. Mueller L., Schutte M., Kugler K., Dehmer M. QuACN: an R package for analyzing complex biological networks quantitatively. *Bioinformatics*, 2011, vol. 27, pp. 140–141. doi:10.1093/bioinformatics/btq606
 22. Bonchi F., De Francisci G., Riondato M. Centrality measures on big graphs: Exact, approximated, and distributed algorithms. *Proc. of the 25th Intern. Conf. "Companion on World Wide Web"*, 2016, pp. 1017–1020. doi:10.1145/2872518.2891063
 23. Brandes U., Borgatti S., Freeman L. Maintaining the duality of closeness and betweenness centrality. *Social Networks*, 2016, vol. 44, pp. 153–159.
 24. Mino A., Salehzadeh-Yazdi A., Razaghi-Moghadam Z., Hennig H., Wolkenhauer O. A systematic survey of centrality measures for protein-protein interaction networks. *BMC Systems Biology*, 2018, vol. 12, no. 1, pp. 80:1–80:17.
 25. Ereemeev I., Tatarka M., Shuvaev F., Cyganov A. Comparative analysis of centrality measures of network nodes based on principal component analysis. *Informatics and Automation*, 2020, vol. 19, no. 6, pp. 1307–1331 (In Russian). doi:10.15622/ia.2020.19.6.7
 26. Shuvaev F. L., Tatarka M. V. Analysis of mathematical models of random graphs used in the simulation of information and communication networks. *Bulletin of St. Petersburg University of the State Fire Service of the Ministry of Emergencies of Russia*, 2020, no. 2, pp. 67–77 (In Russian).
 27. Lê S., Josse J., Husson F. FactoMineR: A package for multivariate analysis. *Journal of Statistical Software*, 2008, vol. 25, iss. 1, pp. 1–18.
 28. Bai L., Cheng X., Liang J., Shen H., Guo Y. Fast density clustering strategies based on the k-means algorithm. *Pattern Recognition*, 2017, vol. 71, pp. 375–386.
 29. Depaolini M., Ciucci D., Calegari S., Dominoni M. External indices for rough clustering. *Lecture Notes in Computer Science*, 2018, vol. 11103.
 30. Joy A., Korobova J. Bootstrapping clustered data in R using lmerSampler. arXiv: 2106.06568, 2021. doi:10.48550/arXiv.2106.06568

Уважаемые авторы!

При подготовке рукописей статей необходимо руководствоваться следующими рекомендациями.

Статьи должны содержать изложение новых научных результатов. Название статьи должно быть кратким, но информативным. В названии недопустимо использование сокращений, кроме самых общепринятых (РАН, РФ, САПР и т. п.).

Текст рукописи должен быть оригинальным, а цитирование и самоцитирование корректно оформлено.

Объем статьи (текст, таблицы, иллюстрации и библиография) не должен превышать эквивалента в 20 страниц, напечатанных на бумаге формата А4 на одной стороне через 1,5 интервала Word шрифтом Times New Roman размером 13, поля не менее двух сантиметров.

Обязательными элементами оформления статьи являются: индекс УДК, заглавие, инициалы и фамилия автора (авторов), ученая степень, звание (при отсутствии — должность), полное название организации, аннотация и ключевые слова на русском и английском языках, ORCID и электронный адрес одного из авторов. При написании аннотации не используйте аббревиатур и не делайте ссылок на источники в списке литературы. Предоставляйте подрисовочные подписи и названия таблиц на русском и английском языках.

Статьи авторов, не имеющих ученой степени, рекомендуется публиковать в соавторстве с научным руководителем, наличие подписи научного руководителя на рукописи обязательно; в случае самостоятельной публикации обязательно предоставляйте заверенную по месту работы рекомендацию научного руководителя с указанием его фамилии, имени, отчества, места работы, должности, ученого звания, ученой степени.

Простые формулы набирайте в Word, сложные с помощью редактора MathType или Equation. Для набора одной формулы не используйте два редактора; при наборе формул в формульном редакторе знаки препинания, ограничивающие формулу, набирайте вместе с формулой; для установки размера шрифта в MathType никогда не пользуйтесь вкладкой Other, Smaller, Larger, используйте заводские установки редактора, не подгоняйте размер символов в формулах под размер шрифта в тексте статьи, не растягивайте и не сжимайте мышью формулы, вставленные в текст; пробелы в формуле ставьте только после запятой при перечислении с помощью Ctrl+Shift+Space (пробел); не отделяйте пробелами знаки: + = ×, а также пространство внутри скобок; для выделения греческих символов в MathType полужирным начертанием используйте Style → Other → bold.

Для набора формул в Word никогда не используйте вкладки: «Уравнение», «Конструктор», «Формула» (на верхней панели: «Вставка» — «Уравнение»), так как этот ресурс предназначен только для внутреннего использования в Word и не поддерживается программами, предназначенными для изготовления оригинал-макета журнала.

При наборе символов в тексте помните, что символы, обозначаемые латинскими буквами, набираются светлым курсивом, русскими и греческими — светлым прямым, векторы и матрицы — прямым полужирным шрифтом.

Подробнее см. <http://i-us.ru/index.php/ius/author-guide>

Иллюстрации:

— рисунки, графики, диаграммы, блок-схемы предоставляйте в виде отдельных исходных файлов, поддающихся редактированию, используя векторные программы: Visio (*.vsd, *.vsdx); Adobe Illustrator (*.ai); Coreldraw (*.cdr, версия не выше 15); Excel (*.xls); Word (*.docx); AutoCad, Matlab (экспорт в PDF, EPS, SVG, WMF, EMF); Компас (экспорт в PDF); веб-портал DRAW.IO (экспорт в PDF); Inkscape (экспорт в PDF);

— фото и растровые — в формате *.tif, *.png с максимальным разрешением (не менее 300 pixels/inch).

Наличие подрисовочных подписей и названий таблиц на русском и английском языках обязательно (желательно не повторяющих дословно комментарий к рисункам в тексте статьи).

В редакцию предоставляются:

— сведения об авторе (фамилия, имя, отчество, место работы, должность, ученое звание, учебное заведение и год его окончания, ученая степень и год защиты диссертации, область научных интересов, количество научных публикаций, домашний и служебный адреса и телефоны, e-mail), фото авторов: анфас, в темной одежде на белом фоне, должны быть видны плечи и грудь, высокая степень четкости изображения без теней и отблесков на лице, фото можно представить в электронном виде в формате *.tif, *.png, *.jpg с максимальным разрешением — не менее 300 pixels/inch при минимальном размере фото 40×55 мм;

— экспертное заключение;

— экспертное заключение.

Список литературы

составляется по порядку ссылок в тексте и оформляется следующим образом:

- для книг и сборников — фамилия и инициалы авторов, полное название книги (сборника), город, издательство, год, общее количество страниц, doi;
- для журнальных статей — фамилия и инициалы авторов, полное название статьи, название журнала, год издания, номер журнала, номера страниц, doi;

— ссылки на иностранную литературу следует давать на языке оригинала без сокращений;

— при использовании web-материалов указывайте адрес сайта и дату обращения.

Список литературы оформляйте двумя отдельными блоками по образцам lit.dot на сайте журнала (<http://i-us.ru/paperrules/>): Литература и References.

Более подробно правила подготовки текста с образцами изложены на нашем сайте в разделе «Руководство для авторов» — <http://i-us.ru/index.php/ius/author-guide>.

Контакты

Куда: 190000, г. Санкт-Петербург, ул. Большая Морская, д. 67, лит. А, ГУАП, РИЦ

Кому: Редакция журнала «Информационно-управляющие системы»

Тел.: (812) 494-70-02

Эл. почта: ius.spb@gmail.com

Сайт: www.i-us.ru



Усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением

Д. И. Милосердов^а, канд. техн. наук, старший научный сотрудник, orcid.org/0000-0002-5312-5531, dmmil94@yandex.ru

^аСанкт-Петербургский Федеральный исследовательский центр РАН, 14-я линия В. О., 39, Санкт-Петербург, 191718, РФ

Введение: прогнозирование групп временных рядов является сложной прикладной проблемой, когда необходимо учитывать как внутрисерийные, так и межсерийные взаимосвязи, оперативно реагировать на изменения в законах формирования рядов. **Цель:** совершенствование систем прогнозирования групп временных рядов, позволяющее повысить точность получаемых прогнозов. **Результаты:** разработана усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением, в состав которой включен блок корректировки, позволяющий автоматически подбирать гиперпараметры прогнозирования и производить наиболее корректный ассоциативный вызов информации из памяти нейронной сети. Предложены новые правила реализации системы в программном исполнении с улучшенным ассоциативным вызовом информации из нейросетевой памяти, что повысило устойчивость функционирования самих нейронных сетей. Разработан и программно реализован алгоритм работы блока корректировки, обеспечивающий подбор коэффициента ослабления, ретроспективной глубины компонентов группового временного ряда, а также порога возбуждения нейронов. Исследована зависимость точности прогнозирования от размера нейросетевых каналов. На примере прогнозирования рыночных показателей продемонстрировано преимущество разработанной системы по сравнению с известными аналогами. **Практическая значимость:** усовершенствованная программная система позволяет получать более точные прогнозы временных рядов для решения задач прикладной направленности. Так, средняя абсолютная ошибка снижается на 2–35 %, средняя абсолютная процентная ошибка на 4–37 % и среднеквадратическая ошибка на 3–29 %. **Обсуждение:** в дальнейшем для повышения эффективности системы необходима разработка правил автоматического выбора других гиперпараметров, а также оптимизация алгоритма их подбора для снижения вычислительных затрат.

Ключевые слова – прогнозирование групп временных рядов, прогнозирование многомерных временных рядов, рекуррентная нейронная сеть, автоматический подбор гиперпараметров, управление ассоциативным вызовом.

Для цитирования: Милосердов Д. И. Усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением. *Информационно-управляющие системы*, 2024, № 1, с. 20–30. doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP

For citation: Miloserdov D. I. Advanced neural network forecasting system with continuous learning for grouped time series. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 20–30 (In Russian). doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP

Введение

Прогнозирование групп временных рядов является сложной прикладной проблемой. Зачастую оно применяется при анализе трудноразделимых процессов, законы проявления которых не могут быть в достаточной полноте описаны одним параметром. Востребовано такое прогнозирование при анализе погодных явлений [1–3], финансовых и экономических показателей [4, 5], дорожно-транспортных событий [6], трафика и энергопотребления [7]. Оно применимо также в сельском хозяйстве [8–10].

В настоящее время к прогнозированию групп временных рядов имеется два основных подхода, называемых локальным и глобальным. Суть локального подхода заключается в том, что вводится предположение о наличии своего закона формирования для каждого ряда. Однако такой подход зачастую неэффективен из-за чрезмер-

ной подгонки модели [11]. На снижение точности прогнозирования в этом случае работает и отсутствие учета взаимосвязей между отдельными рядами. Такое прогнозирование неэффективно в условиях влияния рядов друг на друга, например при прогнозировании дорожного трафика на сети дорог [12]. Тем не менее из-за своей простоты объединение простых прогнозных моделей стало наиболее распространенным подходом к автоматическому прогнозированию временных рядов.

Идея глобального подхода заключается в предположении, что все временные ряды в наборе получены в результате одного и того же процесса. Глобальные методы объединяют данные всех рядов вместе и соответствуют единой одномерной функции прогнозирования [11]. Однако это сложная задача, поскольку необходимо учитывать как внутрисерийные временные корреляции, так и межсерийные корреляции одновременно. В последнее время появилось множество

работ, пытающихся зафиксировать обе корреляции, но большинство, если не все из них, фиксируют только временные корреляции во временной области и прибегают к заранее определенным приоритетам в качестве отношений между рядами [13].

При обработке многомерного временного ряда как единого процесса используют различные подходы. Традиционные методы, такие как многомерная линейная регрессия [1], авторегрессия, гауссов процесс [14], оказываются не в состоянии уловить сложные нелинейные зависимости между временными шагами и между несколькими временными рядами [15, 16]. В свою очередь, возможностей классических архитектур нейронных сетей, таких как долгая краткосрочная память (Long Short-Term Memory – LSTM), оказывается недостаточно для моделирования долговременных зависимостей в условиях многомерного временного ряда. Это вынуждает использовать так называемые глубокие LSTM (Deep LSTM), усложняя архитектуру и ее обучение и прибегая к гибридным методам. Остаются ограниченными и возможности нейросетей по моделированию коррелированных функций, имеющих место в многомерных временных рядах [17]. Кроме того, производительность моделей LSTM может сильно зависеть от выбора величины предыстории прогноза [18]. Согласно [19] графовые нейронные сети продемонстрировали достаточно высокие возможности по извлечению скрытых пространственных зависимостей между парами переменных. Между тем такие сети требуют четко определенных графовых структур для распространения информации, что означает, что они не могут быть применены напрямую для многомерных временных рядов, где зависимости заранее неизвестны.

В работе [2] сверточная нейронная сеть сочетается с декомпозицией временного ряда на несколько рядов, удалением высокочастотной составляющей и извлечением основных характеристик и периодических законов временных рядов. В работе [20] предлагается подход для структурно-параметрической настройки когнитивных моделей, основанных на нечетких правилах. В ней показано, что являются актуальными вопросы выбора оптимальной ретроспективной глубины для исследуемых временных рядов.

Кроме того, большинство существующих моделей временных рядов требуют полных данных временных рядов в качестве входных данных, в то время как в реальных наборах данных временных рядов проблема с недостающими данными почти неизбежна из-за различных факторов. Для таких рядов недавно было предложено несколько примечательных подходов, основанных на матрично-тензорной факторизации. Они по-

казали большие возможности прогнозирования, однако эти модели, как правило, требуют тщательной настройки параметров регуляризации, что в свою очередь ведет к большим вычислительным затратам, и стоимость увеличивается экспоненциально с увеличением количества параметров [12].

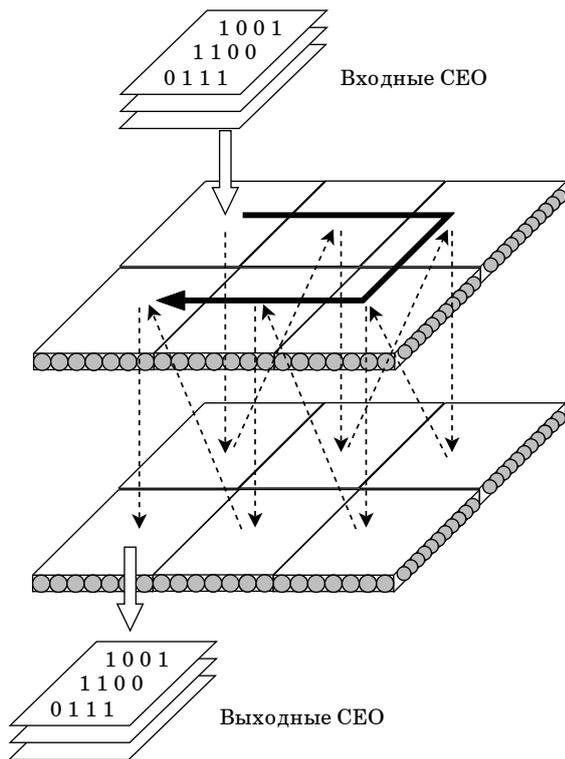
Применяются также гибридные архитектуры [например, 21, 22]. Однако процедура настройки этих моделей должна выполняться для каждой конкретной задачи/набора данных, и универсальных решений в настоящий момент не существует.

Кроме того, законы формирования многомерных временных рядов и их межсерийных связи могут стремительно меняться, что приводит к быстрому устареванию сформированных прогнозных моделей. В таких условиях актуальны методы непрерывного обучения, способные быстро адаптироваться и учитывать новые закономерности при формировании прогнозов.

Постановка задачи совершенствования известной системы нейросетевого прогнозирования групп временных рядов с непрерывным обучением

В последние годы развиваются системы прогнозирования с непрерывным обучением, в основу которых положены рекуррентные нейронные сети (РНС; Recurrent Neural Network – RNN) с управляемыми элементами [23, 24]. Такая нейронная сеть состоит из двух слоев, связанных управляемыми синапсами, и блока управления нейронной сетью. Информационные сигналы передаются посредством единичных импульсов возбужденных нейронов; возбуждение нейрона и излучение импульса происходит при превышении порога возбуждающего потенциала на входе нейрона. Управляемые синапсы сдвигают сигналы при их передаче от слоя к слою, за счет чего реализуется продвижение данных вдоль слоев РНС, от входа к выходу. Слои разбиты на логические поля одинакового размера, а величина сдвига равна размеру логического поля по соответствующей оси. Таким образом, сеть оперирует блоками данных, закодированными в виде состояний нейронов логического поля. Эти блоки данных носят название совокупностей единичных образов (CEO; Sets of Single Patterns – SSP). В зависимости от правил сдвигов CEO при их передаче от слоя к слою, данные могут продвигаться от входа к выходу РНС по различным маршрутам [23, 24]. На рис. 1 приведен пример логической структуры РНС с размером слоев 2×3 логических поля.

В системах прогнозирования с непрерывным обучением имеется две идентичные РНС (РНС1



■ **Рис. 1.** Пример структуры РНС. Черной сплошной стрелкой показан маршрут продвижения СЕО вдоль слоев, черной пунктирной — продвижения от слоя к слою, белой стрелкой показаны точки входа и выхода

■ **Fig. 1.** Example of a structure of RNN. The black solid arrow shows the SSPs route along the layers, the black dotted arrow shows the progress from layer to layer, the white arrow shows the input and output

и РНС2) и блок управления прогнозированием. РНС1 непрерывно находится в режиме обучения. При этом через нее проходит поток данных, закодированных в виде последовательностей СЕО. В процессе такого прохождения на управляемых синапсах посредством изменения их весовых коэффициентов осуществляется установление ассоциативных связей между элементами обрабатываемого потока. Когда возникает необходимость, по команде с блока управления прогнозированием состояние РНС1 копируется в РНС2, и на РНС2 осуществляется прогнозирование [24–26].

Процесс прогнозирования в используемых нейронных сетях осуществляется за счет управления ассоциативным вызовом информации из нейросетевой памяти. Вес синапса, помимо весового коэффициента, включает в свой состав функцию ослабления расходящихся единичных образов [25]

$$\beta_{ij}(t) = 1/(1 + \alpha r_{ij}(t)), \quad (1)$$

которая зависит от коэффициента ослабления α и расстояния между связываемыми синапсом

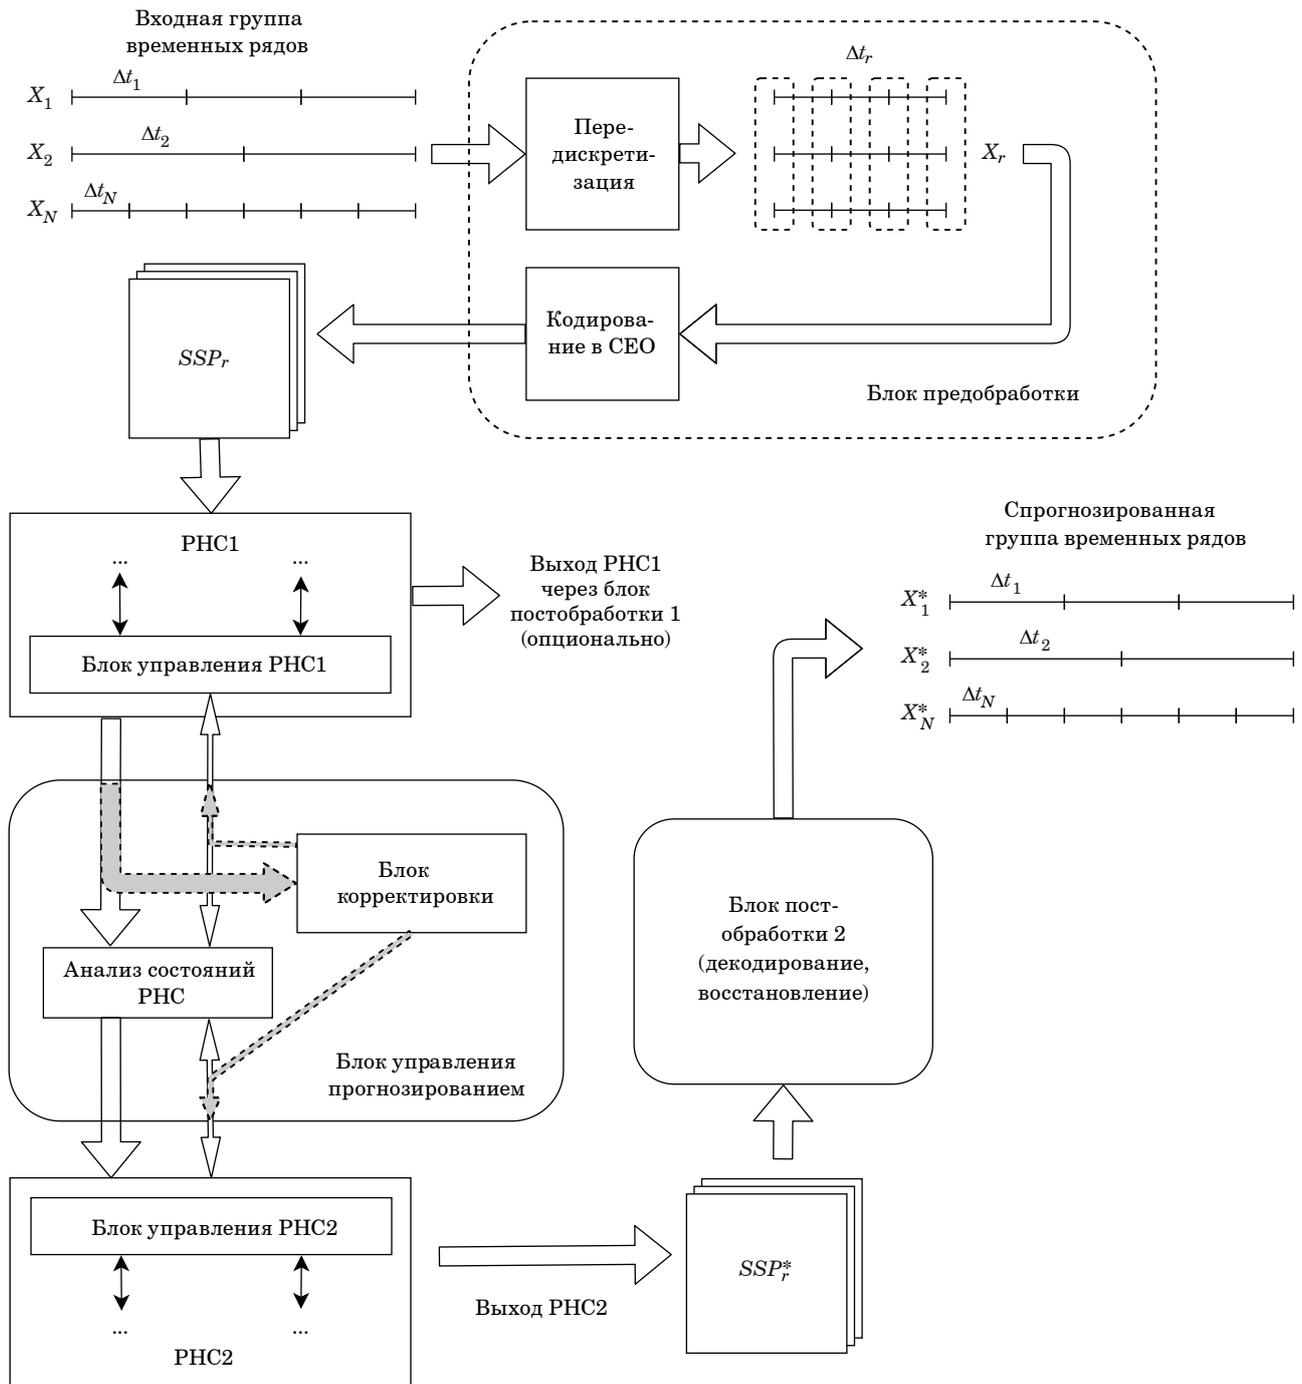
нейронами $r_{ij}(t)$. Варьируя значения α , можно существенно изменять направленность и силу ассоциативного взаимодействия импульсов в сети [25].

Непрерывность обучения и прогнозирования позволяет системе быстро адаптироваться под изменения в законах проявления наблюдаемых событий. Эти свойства делают системы прогнозирования с непрерывным обучением потенциально применимыми для прогнозирования групп временных рядов. В то же время остаются нерешенными вопросы, связанные с управлением гиперпараметрами и устойчивостью функционирования рекуррентных нейронных сетей с управляемыми элементами. Необходимость подбора гиперпараметров приводит к тому, что при отсутствии наблюдения и участия оператора точность прогнозов снижается. Некорректность значений гиперпараметров, таких как порог возбуждения и коэффициент ослабления, может приводить к перегрузке РНС в процессе прогнозирования либо, наоборот, к чрезмерному затуханию и недостатку возбуждающего потенциала нейронов для ассоциативного вызова новой информации. Кроме того, в гиперпараметрах ассоциативного вызова должны быть отражены закономерности наблюдаемого нейросетью потока данных, что не выполняется в случае задания их вручную.

В интересах устранения этих недостатков необходимо усовершенствовать известную систему нейросетевого прогнозирования групп временных рядов с непрерывным обучением.

Усовершенствованная система

Поясним предлагаемые усовершенствования на примере рис. 2. На входе имеются группы временных рядов $\{X_1, X_2, \dots, X_N\}$, которые поступают в блок предобработки. В отличие от известных решений, на блок предобработки, помимо кодирования входного потока в формат СЕО, возлагается задача передискретизации входных рядов и приведения их от собственных интервалов $\Delta t_1, \Delta t_2, \dots, \Delta t_N$ к единому интервалу Δt_r . Метод передискретизации и величина интервала Δt_r выбираются исходя из особенностей временных рядов, которые необходимо обработать, а также аппаратных возможностей используемой вычислительной машины. В блоке предобработки группа временных рядов $\{X_1, X_2, \dots, X_N\}$ преобразуется в набор передискретизированных рядов $\{X_{1r}, X_{2r}, \dots, X_{Nr}\}$, составляющий многомерный ряд X_r , который затем кодируется в последовательность СЕО SSP_r и подается в РНС1. В свою очередь на слоях РНС предусматривается наличие N нейросетевых каналов, по числу об-



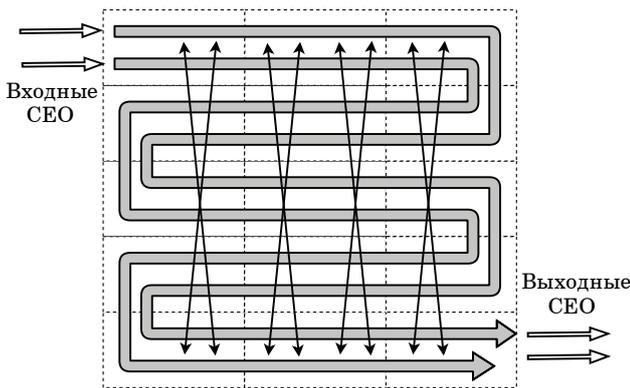
■ **Рис. 2.** Усовершенствованная система прогнозирования групп временных рядов с непрерывным обучением и корректировкой гиперпараметров

■ **Fig. 2.** Improved system for grouped time series forecasting with continuous learning and hyperparameter correction

рабатываемых временных рядов. Под нейросетевым каналом понимается часть нейронов и синапсов РНС, выделяемая для обработки одного временного ряда. Пример канальной структуры слоев РНС для двух рядов и змеевидного маршрута представлен на рис. 3 [24].

В процессе прохождения потока CEO через РНС1 на ее синапсах формируется простран-

ственно-временная модель. Блок управления анализирует состояния слоев РНС и определяет режим прогнозирования [26]. Однако для автоматического подбора гиперпараметров ассоциативного вызова информации из нейросетевой памяти блок управления также наделяется новым блоком, предназначенным для их корректировки. Для этого используется информация о



■ **Рис. 3.** Пример канальной структуры слоев РНС размером 3×5 логических полей (показаны пунктирной линией) для двух нейросетевых каналов (показаны серыми стрелками) и змеевидного маршрута. Тонкими стрелками условно показан процесс установления ассоциативных связей между элементами нейронной сети

■ **Fig. 3.** Example of a channel structure of RNN layers with a size of 3×5 logical fields (shown by a dotted line) for two neural network channels (shown by gray arrows) and a serpentine route. Thin arrows conditionally show the process of establishing associative connections between elements of a neural network

состояниях слоев РНС1 (на рис. 2 показана толстой серой стрелкой). Рассмотрим работу блока корректировки более подробно.

Блок корректировки отвечает за определение порога возбуждения нейронов B и коэффициентов ослабления расходящихся единичных образов α [25]. Кроме того, на этот блок возлагается задача для каждого из рядов $X_{1r}, X_{2r}, \dots, X_{Nr}$ определить глубину предыстории h_1, h_2, \dots, h_N , влияющей на формирование прогнозных значений. Глубина предыстории, используемой в прогнозах для каждого ряда, регулируется длиной фрагмента соответствующего ему нейросетевого канала, при этом

$$h_n \leq H, n = 1, 2, \dots, N, \quad (2)$$

где H — длина нейросетевых каналов в РНС.

Суть работы блока корректировки заключается в подборе значений гиперпараметров, позволяющих произвести наиболее корректный ассоциативный вызов информации из памяти РНС. Процедура ассоциативного вызова прогнозного значения SSP_f в РНС с пространственно-временной моделью W за счет возбуждающего потенциала имеющихся на полях СЕО $SSPs$ описывается выражением

$$SSP_f = RNN(W, SSPs, B, h_n, \alpha), \quad (3)$$

где RNN — оператор обработки в нейросети.

Корректировка основывается на оценке состояний слоев РНС1 во время прохождения данных

через нее и обучения. В логическом поле, копия которого в РНС2 предназначена для получения прогнозных значений, с определенной периодичностью оцениваются величины возбуждающих потенциалов на входах нейронов при различных значениях гиперпараметров. Выбранные значения гиперпараметров из блока корректировки затем передаются в блоки управления нейронными сетями, что на рис. 2 обозначено узкими серыми стрелками. Далее эти значения используются для корректного ассоциативного вызова прогнозных значений.

По результату обработки в РНС2 на выходе имеются спрогнозированные последовательности совокупностей единичных образов SSP_n^* , которые передаются в блок постобработки 2. Данный блок выполняет операции, обратные блоку предобработки: сначала декодирует, а потом восстанавливает исходные частоты, в результате чего на выходе системы имеют место спрогнозированные группы временных рядов $\{X_1^*, X_2^*, \dots, X_N^*\}$.

Программная реализация

Нейросетевая система прогнозирования была реализована программно на языке Qt (C++). Программная реализация заимствует некоторые компоненты программного обеспечения эмуляции пары РНС с управляемыми элементами, использованного в [24], в частности, блок визуализации слоев нейронных сетей. Однако внутренняя логика новой программы существенно отличается. В новой реализации проведен рефакторинг, добавлены функции кодирования и декодирования для многомерного временного ряда, реализована канальная структура слоев с возможностью настройки собственной ретроспективной глубины для каждого канала.

Основным отличием новой программной реализации является функция автоматического подбора гиперпараметров прогнозирования в соответствии с предлагаемым усовершенствованием известного метода. Согласно ему при инициализации системы задается набор комбинаций значений гиперпараметров $\{h_n, \alpha\}$. Диапазон возможных значений ретроспективной глубины определяется условием (2). Коэффициент α согласно [25] не может быть больше 0, в то же время по мере его увеличения вклад обучаемых синапсов в ассоциативный вызов информации из нейросетевой памяти становится пренебрежимо малым.

На этапе обучения, как и в известном методе, РНС1 отводится под прохождение последовательности СЕО и обучение синапсов. Однако при этом с установленной периодичностью про-

исходит запоминание индексов возбужденных нейронов в логическом поле, копия которого в РНС2 отводится под вызов прогнозных значений (для удобства обозначим это поле F_0), и в логических полях, копии которых в РНС2 будут создавать возбуждающий потенциал для этого вызова (F_p). Когда необходимо осуществить процедуру подбора, для каждой комбинации гиперпараметров из имеющегося набора по запомненным индексам нейронов полей F_p осуществляется расчет возбуждающего потенциала нейронов в поле F_0 . В соответствии с выбранной схемой кодирования данных определяется число нейронов в поле F_0 , на входе которых имеется наибольший возбуждающий потенциал, и выбирается такое значение порога B , при котором эти и только эти нейроны были бы возбуждены. Полученная таким образом оценка сравнивается с фактическим состоянием нейронов F_0 , запомненным во время обучения. Степень сходства определяется показателем «пересечения над объединением». В конечном счете, при прогнозировании в РНС2 выбирается та комбинация гиперпараметров, которая соответствует наибольшему значению этого показателя.

Эксперименты и обсуждение

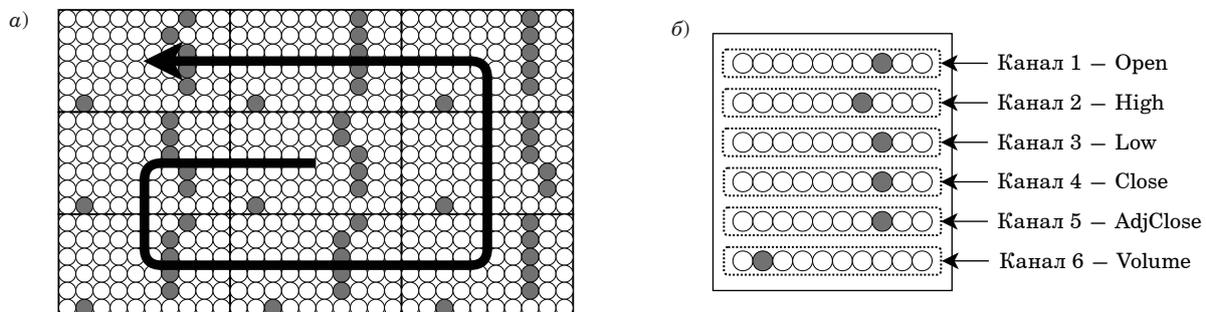
В целях проверки работоспособности усовершенствованной системы проводился ряд экспериментов. В качестве исходных данных для прогнозирования был выбран датасет рыночных показателей Yahoo Finance [27]. Он содержит данные, снимаемые ежедневно (кроме выходных) и включающие показатели: Open, Close, AdjClose – цены на момент открытия и закрытия торгов, смежная цена закрытия; High, Low – наибольшая и наименьшая цена за день; Volume – дневной объем торгов.

В экспериментах прогнозировались все шесть показателей, имеющихся в датасете Yahoo Finance. Таким образом, структура РНС содержала шесть нейросетевых каналов. На кодирование значений каждого канала в первой серии экспериментов отводилось по 10 нейронов. Таким образом, логические поля РНС содержали 60 нейронов. Слои нейронных сетей содержали девять логических полей, маршрут продвижения данных от входа к выходу был выбран в виде расходящейся спирали. Наглядные пояснения структуры РНС, использованной в экспериментах, приведены на рис. 4, а и б.

Кодирование значений каждого показателя осуществлялось следующим образом. Диапазон значений показателя торгов на истории наблюдения разбивался на интервалы, причем количество интервалов равно количеству нейронов в канале. Интервалу, в который попадает текущее значение показателя торгов, ставился в соответствие возбужденный нейрон. Декодирование значений на выходе происходило в обратном порядке.

Для оценивания преимущества по сравнению с другими подходами была выбрана нейронная сеть LSTM. Эта сеть хорошо зарекомендовала себя при обработке временных последовательностей и по сегодня остается одной из самых эффективных и используемых, в том числе при прогнозировании финансово-экономических показателей [28–30].

В каждой серии проведено по семь экспериментов. Глубина прогноза составляла 50 дней, а горизонт – пять дней. Точности прогнозирования определялись по показателям средней абсолютной ошибки (Mean Absolute Error – MAE), средней абсолютной процентной ошибки (Mean Absolute Percentage Error – MAPE), среднеквадратической ошибки (Root Mean Squared Error – RMSE) [24]. Усредненные по приведенным экспе-



■ **Рис. 4.** Структура РНС, использованной в экспериментах: а – общий вид; б – назначение и кодирование показателей торгов в нейросетевых каналах. Серыми кружками показаны возбужденные нейроны, белыми – нейроны в состоянии ожидания, черной стрелкой указан маршрут продвижения данных

■ **Fig. 4.** The structure of the RNN used in the experiments: а – general form; б – assignment and coding of finance indicators in neural network channels. Gray circles show excited neurons, white ones show neurons in a waiting state, the black arrow indicates the route of data

риментам результаты для предлагаемого метода (при размере нейросетевого канала 10 нейронов) и для нейронной сети LSTM приведены в табл. 1.

Полученные результаты свидетельствуют, что усовершенствованная система уверенно превосходит LSTM по усредненным показателям. Так, снижение усредненного MAE по шести показателям торгов составило от 2 до 35 %, MAPE – от 4 до 37 %, RMSE – от 3 до 29 %. Наименьший прирост эффективности достигнут по показателям Close, AdjClose, наибольший – по показателям Open, Low.

Особенностью применения системы является разбиение диапазона значений на интервалы и кодирование интервалов. Это приводит к закруглению результатов пропорционально размеру интервала. Слишком малое число нейронов в канале приводит к увеличению ошибки кодирования, в то же время увеличение числа нейронов при постоянной глубине истории ведет к разреживанию пространственно-временной модели внутри нейронной сети, что также негативно отражается на точности прогнозирования. В целях исследования зависимости величины нейросете-

вых каналов и точности прогнозирования была проведена еще одна серия экспериментов. На тех же исходных данных, что и в первой серии экспериментов, проведено прогнозирование на нейронных сетях с размерами каналов 5, 10, 15 и 20 нейронов. Результаты представлены в табл. 2.

Согласно полученным результатам подтверждается зависимость точности прогнозов от корректного выбора размера нейросетевого канала. В то же время имеется локальный минимум ошибки, который может быть определен на этапе подготовки к прогнозированию, и может быть выбрано целесообразное значение размера нейросетевого канала. В данном примере оно равняется 10. На рис. 5, а–в приведены величины ошибок для всех шести прогнозируемых значений, нормированные для наглядности от 0 до 1. Как видно из рисунков, ошибки снижаются по мере увеличения размера каналов и увеличения точности кодирования и приходят к минимуму при размере канала, равном 10, а затем начинают возрастать, что вызвано увеличением разреженности пространственно-временной модели.

■ **Таблица 1.** Значения ошибок для предлагаемой системы и LSTM

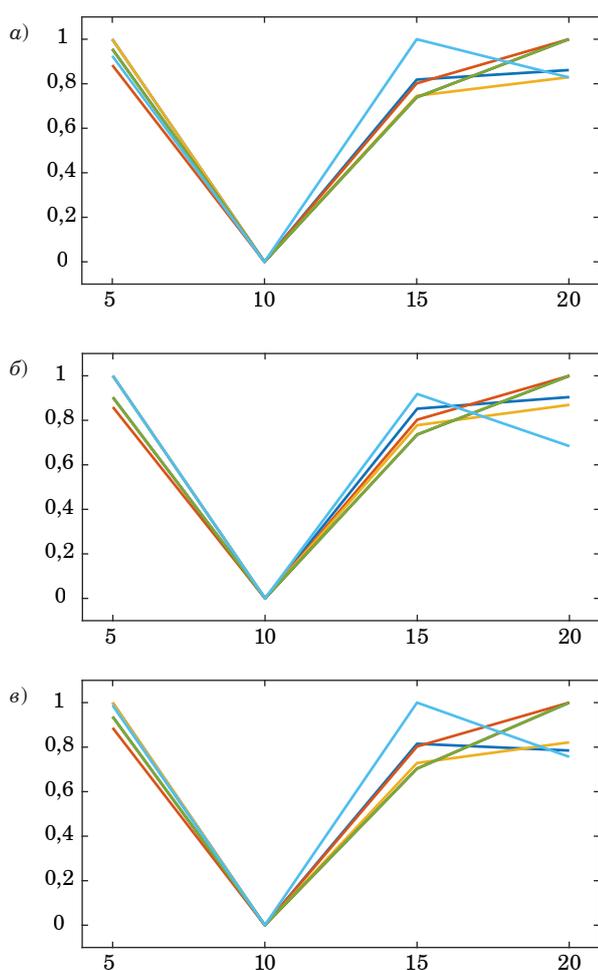
■ **Table 1.** Error values for proposed method and LSTM

Ошибка	Open		High		Low		Close		AdjClose		Volume, ×10 ⁸	
	RNN	LSTM	RNN	LSTM	RNN	LSTM	RNN	LSTM	RNN	LSTM	RNN	LSTM
MAE	42,28	57,38	44,17	52,02	45,42	60,77	57,08	58,54	57,08	59,90	2,73	3,35
MAPE	1,73	2,38	1,78	2,18	1,91	2,58	2,36	2,47	2,36	2,53	10,50	14,34
RMSE	49,06	60,69	48,98	57,17	53,09	68,64	63,91	66,96	63,91	67,15	3,93	4,05

■ **Таблица 2.** Усредненные значения ошибок

■ **Table 2.** Averaged error values

Размер канала	Open	High	Low	Close	AdjClose	Volume, ×10 ⁸
MAE						
5	129,66	124,08	142,47	136,29	136,29	6,18
10	42,28	44,17	45,42	57,08	57,08	2,73
15	113,80	116,66	117,79	118,30	118,30	6,46
20	117,55	134,59	125,91	139,94	139,94	5,82
MAPE						
5	5,18	4,96	5,74	5,44	5,44	26,79
10	1,73	1,78	1,91	2,36	2,36	10,5
15	4,67	4,75	4,89	4,87	4,87	25,46
20	4,85	5,48	5,24	5,77	5,77	21,64
RMSE						
5	133,20	127,32	146,25	140,86	140,86	7,01
10	49,06	48,98	53,09	63,91	63,91	3,93
15	117,64	119,92	120,97	121,71	121,71	7,05
20	115,09	137,33	129,62	146,06	146,06	6,29



■ **Рис. 5.** Динамика ошибок MAE (а), MAPE (б), RMSE (в) в зависимости от величины нейросетевого канала

■ **Fig. 5.** Dynamics of MAE (a), MAPE (б), RMSE (в) errors depending on the size of the neural network channel

Литература

1. **Mudelsee M.** Trend analysis of climate time series: A review of methods. *Earth-Science Reviews*, 2018, vol. 190, pp. 310–322. doi:10.1016/j.earscirev.2018.12.005
2. **Wang J., Li Z.** Wind speed interval prediction based on multidimensional time series of Convolutional Neural Networks. *Engineering Applications of Artificial Intelligence*, 2023, vol. 121, p. 105987. doi:10.1016/j.engappai.2023.105987
3. **Faisal A. N. M., Rahman A., Habib M. T., Siddique A., Hasan M., Khan M.** Neural networks based multivariate time series forecasting of solar radiation using meteorological data of different cities of Bangladesh. *Results in Engineering*, 2022, vol. 13, p. 100365. doi:10.1016/j.rineng.2022.100365
4. **Tran Q. H.** The impact of green finance, economic growth and energy usage on CO₂ emission in Vietnam – a multivariate time series analysis. *China Fi-*

Заключение

В статье предложена усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением. На примере прогнозирования группы показателей торгов датасета Yahoo Finance показано, что предлагаемая система позволяет снижать ошибки MAE от 2 до 35 %, MAPE от 4 до 37 %, RMSE от 3 до 29 % по сравнению с известными решениями на основе LSTM. Высокая точность прогнозов обуславливается повышением гибкости управления ассоциативным вызовом информации из нейросетевой памяти. В то же время метод чувствителен к правильности выбора размеров нейросетевых каналов. Показано, что слишком большое или слишком малое количество кодирующих нейронов в нейросетевом канале способно приводить к снижению точности.

В дальнейших исследованиях планируется сосредоточиться на разработке механизмов автоматического определения требуемой величины канала прямо в процессе работы системы. Другим направлением совершенствования системы прогнозирования станет оптимизация процесса подбора гиперпараметров, поскольку перебор возможных их комбинаций становится вычислительно затратным при увеличении числа временных рядов в прогнозируемой группе.

Финансовая поддержка

Исследование выполнено за счет гранта Российского научного фонда № 23-19-20081 (<https://rscf.ru/project/23-19-20081/>) и Санкт-Петербургского научного фонда.

nance Review International, 2022, vol. 12, no. 2, pp. 280–296. doi:10.1108/CFRI-03-2021-0049

5. **Mehtab S., Sen J.** Analysis and forecasting of financial time series using CNN and LSTM-based deep learning models. *2nd Intern. Conf. on Advances in Distributed Computing and Machine Learning (ICADCML '21)*, January 15–16, 2021, Bhubaneswar, India, 2020. doi:10.13140/RG.2.2.22226.38083/1
6. **Praveen Kumar B., Hariharan K.** Multivariate time series traffic forecast with long short term memory based deep learning model. *Intern. Conf. on Power, Instrumentation, Control and Computing (PICC 2020)*, December 17–19, 2020, Thrissur, India, 2020, pp. 1–5. doi:10.1109/PICC51425.2020.9362455
7. **Jin M., Zheng Y., Li Y. F., Chen S., Yang B., Pan S.** Multivariate time series forecasting with dynamic graph neural ODEs. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 9, pp. 9168–9180. doi:10.1109/TKDE.2022.3221989

8. **Dittrich I., Gertz M., Maassen-Francke B., Kru-dewig K.-H., Junge W., Krieter J.** Estimating risk probabilities for sickness from behavioural patterns to identify health challenges in dairy cows with multivariate cumulative sum control charts. *Animal*, 2022, vol. 16, p. 100601. doi:10.1016/j.animal.2022.100601
9. **Hounslow J., Fossette S., Byrnes E., Whiting S., Lambourne R., Armstrong N., Tucker A., Richardson A., Gleiss A.** Multivariate analysis of biologging data reveals the environmental determinants of diving behaviour in a marine reptile. *Royal Society Open Science*, 2022, vol. 9, iss. 8. doi:10.1098/rsos.211860
10. **Santos A., Medeiros V., Gonçalves G.** Monitoring and classification of cattle behavior: A survey. *Smart Agricultural Technology*, 2023, vol. 3, p. 100091. doi:10.1016/j.atech.2022.100091
11. **Montero-Manso P., Hyndman R.** Principles and algorithms for forecasting groups of time series: Locality and globality. *International Journal of Forecasting*, 2021, vol. 37, iss. 4, pp. 1632–1653. doi:10.1016/j.ijforecast.2021.03.004
12. **Chen X., Sun L.** Bayesian temporal factorization for multidimensional time series prediction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, vol. 44, iss. 9, pp. 4659–4673. doi:10.1109/TPAMI.2021.3066551
13. **Cao D., Wang Y., Duan J., Zhang C., Zhu X., Huang C., Tong Y., Xu B., Bai J., Tong J., Zhang Q.** Spectral temporal graph neural network for multivariate time-series forecasting. *Machine Learning*, 2021. doi.org/10.48550/arXiv.2103.07719
14. **Wan R., Mei S., Wang J., Liu M., Yang F.** Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*, 2019, vol. 8, iss. 8, p. 876. doi:10.3390/electronics8080876
15. **Huang S., Wang D., Wu X., Tang A.** DSANet: Dual self-attention network for multivariate time series forecasting. *Proc. of the 28th ACM Intern. Conf. on Information and Knowledge Management (CIKM '19)*, Association for Computing Machinery, New York, 2019, pp. 2129–2132. doi:10.1145/3357384.3358132
16. **Wallot S., Mønster D.** Multidimensional joint recurrence quantification analysis: detecting coupling between time series of different dimensionalities. *Data Analysis, Statistics and Probability*, 2023. arXiv. 2303.16907
17. **Sagheer A., Kotb M.** Unsupervised pre-training of a deep LSTM-based stacked autoencoder for multivariate time series forecasting problems. *Scientific Reports*, 2019, vol. 9, p. 19038. doi:10.1038/s41598-019-55320-6
18. **Zhang T., Song S., Li S., Ma L., Pan S., Han L.** Research on gas concentration prediction models based on LSTM multidimensional time series. *Energies*, 2019, vol. 12, iss. 1, p. 161. doi:10.3390/en12010161
19. **Wu Z., Pan S., Long G., Jiang J., Chang X., Zhang C.** Connecting the dots: Multivariate time series forecasting with graph neural networks. *Proc. of the 26th ACM SIGKDD Intern. Conf. on Knowledge Discovery & Data Mining*, 2020, pp. 753–763. doi:10.1145/3394486.3403118
20. **Borisov V., Luferov V.** Forecasting of multidimensional time series basing on fuzzy rule-based models. *XXI Intern. Conf. Complex Systems: Control and Modeling Problems (CSCMP)*, 2019. doi:10.1109/CSCMP45713.2019.8976821
21. **Xu X., Ren W.** A hybrid model of stacked autoencoder and modified particle swarm optimization for multivariate chaotic time series forecasting. *Applied Soft Computing*, 2021, vol. 116, p. 108321. doi:10.1016/j.asoc.2021.108321
22. **Castán-Lascorz M. A., Jiménez-Herrera P., Troncoso A., Cortés G.** A new hybrid method for predicting univariate and multivariate time series based on pattern forecasting. *Information Sciences*, 2021, vol. 586. doi:10.1016/j.ins.2021.12.001
23. **Osipov V., Osipova M.** Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*, 2018, vol. 308, pp. 194–204. doi:10.1016/j.neucom.2018.05.009
24. **Osipov V., Nikiforov V., Zhukova N., Miloserdov D.** Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*, 2020, vol. 32, pp. 14885–14897. doi:10.1007/s00521-020-04843-5
25. **Осипов В. Ю., Милосердов Д. И.** Нейросетевое прогнозирование событий для роботов с непрерывным обучением. *Информационно-управляющие системы*, 2020, № 5, с. 33–42. doi:10.31799/1684-8853-2020-5-33-42
26. **Осипов В. Ю., Кулешов С. В., Милосердов Д. И., Зайцева А. А., Аксенов А. Ю.** Рекуррентные нейронные сети с непрерывным обучением в задачах многофункциональной обработки новостных потоков. *Информатика и автоматизация*, 2022, т. 21, № 6, с. 1145–1168. doi:10.15622/ia.21.6.3
27. **YFinance.** <https://pypi.org/project/yfinance/> (дата обращения: 26.07.2023).
28. **Siami-Namini S., Namin A. S.** Forecasting economics and financial time series: ARIMA vs. LSTM. *Machine Learning*, 2018. doi.org/10.48550/arXiv.1803.06386
29. **Mehtab S., Sen J.** *Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models*. Advances in Distributed Computing and Machine Learning. Lecture Notes in Networks and Systems, 2022, vol. 302, pp. 405–423. doi:10.1007/978-981-16-4807-6_39
30. **Sirisha U. M., Belavagi M. C., Attigeri G.** Profit prediction using ARIMA, SARIMA and LSTM models in time series forecasting: A comparison. *IEEE Access*, 2022, vol. 10, pp. 124715–124727. doi:10.1109/ACCESS.2022.3224938

UDC 004.827

doi:10.31799/1684-8853-2024-1-20-30

EDN: FRWKWP

Advanced neural network forecasting system with continuous learning for grouped time seriesD. I. Miloserdov^a, PhD, Tech., Senior Researcher, orcid/org/0000-0002-5312-5531, dmmil94@yandex.ru^aSt. Petersburg Federal Research Center of the RAS, 39, 14th Line, 199178, Saint-Petersburg, Russian Federation

Introduction: Forecasting of grouped time series is a complex applied problem when it is necessary to take into account both intra-series and inter-series relationships, and promptly respond to changes in the laws of series formation. **Purpose:** To improve forecasting systems for grouped time series, allowing to increase the accuracy of the received forecasts. **Results:** We develop an improved system of neural network forecasting of grouped time series with continuous learning, which includes the correction unit that allows to automatically select hyperparameters of forecasting and make the most correct associative call of information from the neural network memory. We propose new rules for the implementation of the system in software execution with improved associative recall of information from neural network memory, which increases the stability of the functioning of neural networks themselves. We develop and programmatically implement the algorithm of the correction unit operation, which provides the selection of the attenuation coefficient, the retrospective depth of the components of the grouped time series, as well as the threshold of neuronal excitation. The dependence of prediction accuracy on the size of neural network channels is investigated. The example of forecasting market indicators demonstrates the advantage of the developed system in comparison with known analogues. **Practical relevance:** The improved software system makes it possible to obtain more accurate time series forecasts for solving applied problems. Thus, the average absolute error is reduced by 2–35%, the average absolute percentage error by 4–37% and the standard error by 3–29%. **Discussion:** In the future, to increase the efficiency of the system, it is necessary to develop rules for the automatic selection of other hyperparameters, as well as to optimize the algorithm for their selection to reduce computational costs.

Keywords – grouped time series forecasting, multidimensional time series forecasting, recurrent neural network, automatic selection of hyperparameters, control of associative recall.

For citation: Miloserdov D. I. Advanced neural network forecasting system with continuous learning for grouped time series. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 20–30 (In Russian). doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP

Financial support

The research is supported by the grant of Russian Science Foundation No. 23-19-20081 (<https://rscf.ru/en/project/23-19-20081/>) and Saint-Petersburg Science Foundation.

References

- Mudelsee M. Trend analysis of climate time series: A review of methods. *Earth-Science Reviews*, 2018, vol. 190, pp. 310–322. doi:10.1016/j.earscirev.2018.12.005
- Wang J., Li Z. Wind speed interval prediction based on multidimensional time series of Convolutional Neural Networks. *Engineering Applications of Artificial Intelligence*, 2023, vol. 121, p. 105987. doi:10.1016/j.engappai.2023.105987
- Faisal A. N. M., Rahman A., Habib M. T., Siddique A., Hasan M., Khan M. Neural networks based multivariate time series forecasting of solar radiation using meteorological data of different cities of Bangladesh. *Results in Engineering*, 2022, vol. 13, p. 100365. doi:10.1016/j.rineng.2022.100365
- Tran Q. H. The impact of green finance, economic growth and energy usage on CO₂ emission in Vietnam – a multivariate time series analysis. *China Finance Review International*, 2022, vol. 12, no. 2, pp. 280–296. doi:10.1108/CFRI-03-2021-0049
- Mehtab S., Sen J. Analysis and forecasting of financial time series using CNN and LSTM-based deep learning models. *2nd Intern. Conf. on Advances in Distributed Computing and Machine Learning (ICADCML '21)*, Bhubaneswar, India, 2020. doi:10.13140/RG.2.2.22226.38083/16
- Praveen Kumar B., Hariharan K. Multivariate time series traffic forecast with long short term memory based deep learning model. *Intern. Conf. on Power, Instrumentation, Control and Computing (PICC 2020)*, Thrissur, India, 2020, pp. 1–5. doi:10.1109/PICC51425.2020.9362455
- Jin M., Zheng Y., Li Y. F., Chen S., Yang B., Pan S. Multivariate time series forecasting with dynamic graph neural ODEs. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 9, pp. 9168–9180. doi:10.1109/TKDE.2022.3221989
- Dittrich I., Gertz M., Maassen-Francke B., Krudewig K.-H., Junge W., Krieter J. Estimating risk probabilities for sickness from behavioural patterns to identify health challenges in dairy cows with multivariate cumulative sum control charts. *Animal*, 2022, vol. 16, p. 100601. doi:10.1016/j.animal.2022.100601
- Hounslow J., Fossette S., Byrnes E., Whiting S., Lambourne R., Armstrong N., Tucker A., Richardson A., Gleiss A. Multivariate analysis of biologging data reveals the environmental determinants of diving behaviour in a marine reptile. *Royal Society Open Science*, 2022, vol. 9, iss. 8. doi:10.1098/rsos.211860
- Santos A., Medeiros V., Gonçalves G. Monitoring and classification of cattle behavior: a survey. *Smart Agricultural Technology*, 2023, vol. 3, p. 100091. doi:10.1016/j.atech.2022.100091
- Montero-Manso P., Hyndman R. Principles and algorithms for forecasting groups of time series: Locality and globality. *International Journal of Forecasting*, 2021, vol. 37, iss. 4, pp. 1632–1653. doi:10.1016/j.ijforecast.2021.03.004
- Chen X., Sun L. Bayesian temporal factorization for multidimensional time series prediction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, vol. 44, iss. 9, pp. 4659–4673. doi:10.1109/TPAMI.2021.3066551
- Cao D., Wang Y., Duan J., Zhang C., Zhu X., Huang C., Tong Y., Xu B., Bai J., Tong J., Zhang Q. Spectral temporal graph neural network for multivariate time-series forecasting. *Machine Learning*, 2021. doi.org/10.48550/arXiv.2103.07719
- Wan R., Mei S., Wang J., Liu M., Yang F. Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*, 2019, vol. 8, iss. 8, p. 876. doi:10.3390/electronics8080876
- Huang S., Wang D., Wu X., Tang A. DSANet: Dual self-attention network for multivariate time series forecasting. *Proc. of the 28th ACM Intern. Conf. on Information and Knowledge Management (CIKM '19)*, Association for Computing Machinery, New York, 2019, pp. 2129–2132. doi:10.1145/3357384.3358132
- Wallot S., Mønster D. Multidimensional joint recurrence quantification analysis: detecting coupling between time series of different dimensionalities. *Data Analysis, Statistics and Probability*, 2023. arXiv:2303.16907
- Sagheer A., Kotb M. Unsupervised pre-training of a deep LSTM-based stacked autoencoder for multivariate time series forecasting problems. *Scientific Reports*, 2019, vol. 9, p. 19038. doi:10.1038/s41598-019-55320-6
- Zhang T., Song S., Li S., Ma L., Pan S., Han L. Research on gas concentration prediction models based on LSTM multidimensional time series. *Energies*, 2019, vol. 12, iss. 1, p. 161. doi:10.3390/en12010161
- Wu Z., Pan S., Long G., Jiang J., Chang X., Zhang C. Connecting the dots: Multivariate time series forecasting with

- graph neural networks. *Proc. of the 26th ACM SIGKDD Intern. Conf. on Knowledge Discovery & Data Mining*, 2020, pp. 753–763. doi:10.1145/3394486.3403118
20. Borisov V., Luferov V. Forecasting of multidimensional time series basing on fuzzy rule-based models. *XXI Intern. Conf. Complex Systems: Control and Modeling Problems (CSCMP)*, 2019. doi:10.1109/CSCMP45713.2019.8976821
 21. Xu X., Ren W. A hybrid model of stacked autoencoder and modified particle swarm optimization for multivariate chaotic time series forecasting. *Applied Soft Computing*, 2021, vol. 116, p. 108321. doi:10.1016/j.asoc.2021.108321
 22. Castán-Lascorz M. A., Jiménez-Herrera P., Troncoso A., Cortés G. A new hybrid method for predicting univariate and multivariate time series based on pattern forecasting. *Information Sciences*, 2021, vol. 586. doi:10.1016/j.ins.2021.12.001
 23. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*, 2018, vol. 308, pp. 194–204. doi:10.1016/j.neucom.2018.05.009
 24. Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers. *Neural Computing and Applications*, 2020, vol. 32, pp. 14885–14897. doi:10.1007/s00521-020-04843-5
 25. Osipov V. Yu., Miloserdov D. I. Neural network event forecasting for robots with continuous training. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 33–42 (In Russian). doi:10.31799/1684-8853-2020-5-33-42
 26. Osipov V., Kuleshov S., Miloserdov D., Zaytseva A., Aksenov A. Recurrent neural networks with continuous learning in problems of news streams multifunctional processing. *Informatics and Automation*, 2022, vol. 21, no. 6, pp. 1145–1168 (In Russian). doi:10.15622/ia.21.6.3
 27. *YFinance*. Available at: <https://pypi.org/project/yfinance/> (accessed 26 July 2023).
 28. Siami-Namini S., Namin A. S. Forecasting economics and financial time series: ARIMA vs. LSTM. *Machine Learning*, 2018. doi.org/10.48550/arXiv.1803.06386
 29. Mehtab S., Sen J. *Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models*. In: *Advances in Distributed Computing and Machine Learning*. Lecture Notes in Networks and Systems, 2022, vol. 302, pp. 405–423. doi:10.1007/978-981-16-4807-6_39
 30. Sīrisha U. M., Belavagi M. C., Attigeri G. Profit prediction using ARIMA, SARIMA and LSTM models in time series forecasting: A comparison. *IEEE Access*, 2022, vol. 10, pp. 124715–124727. doi:10.1109/ACCESS.2022.3224938

УВАЖАЕМЫЕ АВТОРЫ!

Научные базы данных, включая Scopus и Web of Science, обрабатывают данные автоматически. С одной стороны, это ускоряет процесс обработки данных, с другой — различия в транслитерации ФИО, неточные данные о месте работы, области научного знания и т. д. приводят к тому, что в базах оказывается несколько авторских страниц для одного и того же человека. В результате для всех по отдельности считаются индексы цитирования, что снижает рейтинг ученого.

Для идентификации авторов в сетях Thomson Reuters проводит регистрацию с присвоением уникального индекса (ID) для каждого из авторов научных публикаций.

Процедура получения ID бесплатна и очень проста, есть возможность провести регистрацию на 12 языках, включая русский (чтобы выбрать язык, кликните на зеленое поле сверху справа на стартовой странице): <https://orcid.org>

UDC 007.52:004.896:51-74

doi:10.31799/1684-8853-2024-1-31-43

EDN: WPZYLY

Articles



Synthesis of a hybrid underlying surface classifier based on fuzzy logic using current consumption of mobile robot motion

A. S. Belyaev^a, PhD, Tech., Senior Lecturer, orcid.org/0000-0002-0725-4690, asb22@tpu.ru

O. Yu. Kushnarev^a, Post-Graduate Student, orcid.org/0009-0004-6793-0162

O. A. Brylev^a, Programmer Engineer, orcid.org/0009-0006-8512-2518

^aNational Research Tomsk Polytechnic University, 30, Lenina Ave., 634050, Tomsk, Russian Federation

Introduction: One approach to solving navigation and control problems for outdoor mobile robots is to use real-time classification of the underlying surface type over which the robot is traveling. Knowledge of the underlying surface type allows one to use previously known surface characteristics to improve localization accuracy and control algorithms. **Purpose:** To research applicability of the energy cost of motion for solving the problem of classifying surfaces with different physical properties for a robot with complex kinematics. **Results:** The analysis of multi-component motion types has shown that the best distinguishing between surfaces is achieved by using the motor current values. A fuzzy classifier is synthesized on data that was grouped according to the criterion of the most impactful motor in a selected direction of motion. We then compare the classifier with machine learning methods. Machine learning algorithms outperform the fuzzy logic in terms of average accuracy, but fall behind in terms of generalization. We propose a fuzzy logic – machine learning hybrid in order to preserve the generalization of the fuzzy classifier and improve the accuracy of surface detection by considering more patterns using machine learning methods. The proposed method for analyzing and classifying data allows us to distinguish with high accuracy between surfaces differing in power consumption levels, including those that are formed due to different surface properties. **Practical relevance:** Results of the research can be employed in developing either a standalone surface classifier or a component of a complex classifier with varying input data types.

Keywords – underlying surface classification, hybrid methods, machine learning, fuzzy logic, decision trees, gradient boosting, mobile robotics, motor consumption current analysis.

For citation: Belyaev A. S., Kushnarev O. Yu., Brylev O. A. Synthesis of a hybrid underlying surface classifier based on fuzzy logic using current consumption of mobile robot motion. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 31–43. doi:10.31799/1684-8853-2024-1-31-43, EDN: WPZYLY

Introduction

One approach to solving navigation and control problems for outdoor mobile robots is to use real-time classification of the underlying surface type over which the robot is traveling. They traverse different surfaces such as soil, sand, stones, snow, ice, concrete, asphalt and others.

Knowledge of the underlying surface type allows previously known surface characteristics to be used to improve localization accuracy and control algorithms. In this case, controlling the mobile robot using internal parameters and coordinates measured by the robot's sensitive elements is particularly valuable. This approach provides greater autonomy and is sometimes the only technically feasible option. To obtain additional information about the underlying surface, it is proposed to determine its type using the robot's internal measured variables. In this case, the classifier will consider previously known surface characteristics, including their impact on the robot. This will provide additional information for solving problems related to local navigation, design adaptation, and control algorithms, resulting in a qualitatively different outcome.

In our opinion, there are four main approaches to solving the surface classification task, which vary according to the information given to the classifier and the way the surface affects the robot's movement.

The first approach is to use visual information about the surface. This way we can obtain indirect information about the surface parameters. For example, roughness, color, and uniformity. Cameras are used as sensors. In this case, the images of the surface can be taken in front of the robot [1] or under its wheels [2]. The main advantages of this category are the independence from the design of the mobile robot and the ability to determine the type of surface before moving on it. The disadvantages are dependence on sensor operating conditions (the influence of lighting, dust, precipitation, vibrations) and the inability to directly determine the characteristics of the surface, which are important parameters for solving other problems. Therefore, in most studies, this method is fused with methods based on other data. For example, visual data is combined with inertial sensor readings as in [3, 4] or with acoustic signals corresponding to the surfaces under investigation [2, 5]. In [3] the classification ac-

curacy using the visual method ranged from 73.6 to 96.4% depending on the method applied.

The second approach is to identify the surface topography during locomotion. In this case, we obtain surface characteristics directly through the robot's interaction with it. The topography can be derived through the vibration of the mobile robot's structure components. For this purpose, acoustic sensors (microphones) [6] and inertial systems mounted on the robot's actuators (Inertial Measurement Unit – IMU) [7–9] can be used. To develop a classifier, initial tests are necessary to collect data on the surfaces where the robot will operate. Hence, classification is based on comparing with known test data. In [10] there are results of surface classification by different types of input data, including the surface topology obtained by IMU. It shows that this approach achieves high accuracy (>80%) for rough surfaces and low accuracy (about 33–63%) for smooth and soft surfaces. A tapered spring attached to a mobile robot can act as a sensor for vibration detection [11]. Ideologically, this principle can be implemented for the robot's suspension. Displacement of magnets fixed on the spring is determined by hall sensors to measure the spring vibration. At the same time, the acquired vibration data is used for subsequent AI-based classification with an accuracy ranging from 80 to 89% on the trained data and from 77 to 89% on new data [11]. Another direct topography identification method is based on the use of surface-reflected sound signals of different frequencies emitted from the robot [12]. Here, the average classification accuracy on three types of surfaces – grass, sand, and concrete – was 97.33%.

In general, this approach is widely used. It provides valuable information about surface relief and allows to classify it with high accuracy. The topography is an important characteristic of the surface that is often used to evaluate its impact on the mobile robot. Nevertheless, this can only be achieved by relying on the previously derived dependencies between the relief and the robot's motion. One of the drawbacks of using this approach is the reduced accuracy when dealing with smooth and soft surfaces.

The third approach is to use information about the propulsor's contact force with the surface. In this case, the reaction forces at the contact points are measured. Therefore, surface characteristics directly obtained through robot-ground contact. It is widely studied by terramechanics. In this case, F/T sensors are primarily used. They can be installed on the propulsion system either separately or as a combination of several dozens of sensors. In general, this approach is widespread for walking robots. In [13, 14] an average accuracy of 91–93% is obtained depending on the used approach to data preparation and analysis. Applying this method for a walking robot [15] using a special motion resulted in classify-

ing surfaces with an average accuracy ranging from 62.00 to 97.50% depending on the number of considered surface features and on the chosen machine learning model. In [16] arrays of F/T sensors on a flex circuit are placed on the C-shaped legs of the robot. A classifier performs better on soft surfaces (grass, gravel, sand) with accuracies of 92–97% than on hard surfaces (concrete, tile) with accuracies around 70%.

The advantage of this approach lies in the direct focus on the robot's contact with the surface. Consequently, it is possible to determine its characteristics. For example, for wheeled robots [17–19] this approach allows for the determination of underlying surface parameters such as surface cohesion and internal friction angle. However, additional information must be used to evaluate the direct effect on the robot. The disadvantages are the difficulties in determining the surface and the design limitation of installing such sensors.

The fourth approach – we propose to use information about the energy cost of motion. This information characterizes the impact of the surface on the robot, rather than the surface itself. The power consumption can be evaluated using basic sensors integrated into the platform, such as the draw current and voltage sensors of the actuators. Therefore, in essence, we use internal measurable states of the system. Current sensors of motors are primarily used. In this case for DC motors, this information can be applied to calculate the torque applied to each wheel [20]. Often this information is combined with information from other sensors, such as encoders [21]. In [10], the values of motor voltages and currents are used to classify 5 types of outdoor surfaces using a neural network: gravel, grass, sand, pavement, and dirt. The average accuracy on motor currents in the time domain was 56.9%. The classifier on motor currents performed best on smooth surfaces with accuracies in the range of 76–83%. Motor current was shown to be the best parameter for sand identifying among all other methods.

However, most often, the energy-based approach is used not for surface classification tasks, but for obtaining the parameters affecting the motion like rolling resistance, wheel slippage [16, 18, 22]. The advantage of this method is the ability to evaluate the surface impact on the robot directly. This is important to designing effective control systems. The disadvantages are: the difficulty in identifying the surface topography, dependence on robot kinematics and control actions such as speed and type of motion.

An analysis of the advantages and disadvantages of the above approaches shows that none of them can solve the surface classification problem with high accuracy for a wide class of robots and a large number of underlying surfaces. This conclusion is sup-

ported by results presented in a study [10], where an analysis of various sensor data groups showed the prevalence of different methods for different surface types. Consequently, the relevance of the study is confirmed by the lack of a general methodology. At the moment, there are only specific solutions to this problem with predetermined conditions. In terms of control algorithms, the proposed approach, that is based on direct evaluation of the surface's effect on the robot, will solve the problem of surface classification while also allowing to directly control the robot depending on the required character of motion.

However, classifiers based on the fourth approach, that use information about power consumption have not been thoroughly researched. Therefore, this paper focuses on investigating the applicability of these insights to the classification task. The problem is complicated by a complex kinematic structure of the robot and varying motion velocities. The classifier based on this approach can be used in the future in a universal classifier, which will combine different approaches to solving the problem of surface recognition. Of particular interest is the study of such a classifier on surfaces with a wide range of physical parameters, including those that are weakly correlated with power consumption.

Experimental setup

The schematic design of the experimental setup is shown in Fig. 1. The Festo Robotino 1.6 mobile robot is used for the experiments (Fig. 1, a).

This robot has a wheelbase on omni-wheels, which allows it to move in any direction without ro-

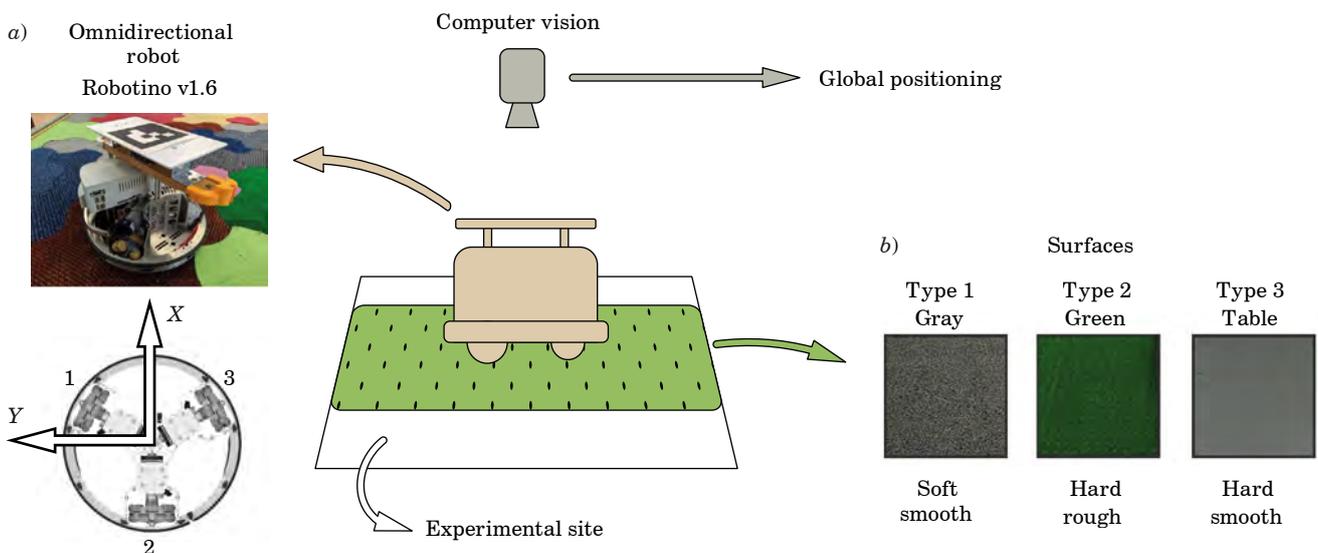
tating the entire structure. Such wheelbase makes the classification task more challenging due to the mutual influence of the wheels during movement. There may be situations where the frictional force of the wheel does not align with the vector of linear motion of the wheel. This effect can be compared to lateral slippage on a slippery or inclined surface, as seen in outdoor robotics. The use of a robot with an omnidirectional platform is a more general and complex case for solving the classification task.

The robot is controlled through velocities in the local coordinate system. It is equipped with three DC motors. Each motor has a current sensor and a shaft-mounted encoder. The mobile platform moves on a test site with interchangeable types of underlying surface: type 1 – soft smooth (gray); type 2 – hard rough (green); type 3 – hard smooth (table) (Fig. 1, b). Each surface has a different effect on the robot's motion. Note that type 1 and type 2 surface have close values of power consumption parameter, but it is formed due to different surface properties (gray – softness, green – topography). Similar surfaces were also researched in [21, 23, 24].

Consequently, the following control parameters are varied in the experiments:

- underlying surface type (3 surface types);
- the amplitude of the robot's velocity (from 0.1 to 0.3 m/s);
- direction of robot's speed (26 directions, including rotational component).

During the experiment, the following sensor system data are read from the robot at a sampling rate of 0.1 s: wheel angular velocity $\{\omega_i\}$ and consumption current for each motor $\{I_1, I_2, I_3\}$. It is not possible to get a direct measurement of a motor's voltage on the Festo Robotino 1.6. Therefore, we will solely



■ **Fig. 1.** Experimental setup: a – appearance, coordinate system and motor arrangement of the Festo Robotino 1.6; b – surface types

rely on information from current sensors to solve the classification task based on power consumption. Additionally, the following parameters are calculated using the values of the current draw [21, 23]:

– currents along the mobile platform movement axes $\{I_x, I_y, I_\varphi\}$:

$$\begin{pmatrix} I_x \\ I_y \\ I_\varphi \end{pmatrix} = \begin{pmatrix} -\frac{2}{3}\cos(\alpha-\theta) & -\frac{2}{3}\sin(\alpha-\theta) & \frac{2}{3}\cos(\alpha+\theta) \\ -\frac{2}{3}\sin(\alpha-\theta) & -\frac{2}{3}\cos(\alpha) & \frac{2}{3}\sin(\alpha-\theta) \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix} \begin{pmatrix} I_1 \\ I_2 \\ I_3 \end{pmatrix};$$

– forces along the axes $\{F_x, F_y\}$ and robot torque M_Ω :

$$\begin{pmatrix} F_x \\ F_y \\ M_\Omega \end{pmatrix} = \frac{1}{r} \begin{pmatrix} -\cos\left(\frac{\pi}{6}\right) & \sin(0) & \cos\left(\frac{\pi}{6}\right) \\ -\sin\left(\frac{\pi}{6}\right) & \cos(0) & \sin\left(\frac{\pi}{6}\right) \\ L & L & L \end{pmatrix} \begin{pmatrix} M_1 \\ M_2 \\ M_3 \end{pmatrix};$$

– total current consumption of the motors

$$I_\Sigma^{motor} = |I_1| + |I_2| + |I_3|;$$

– total current along the platform movement axes

$$I_\Sigma^{axes} = |I_x| + |I_y| + |I_\varphi|;$$

– torques on the motors $\{M_1, M_2, M_3\}$:

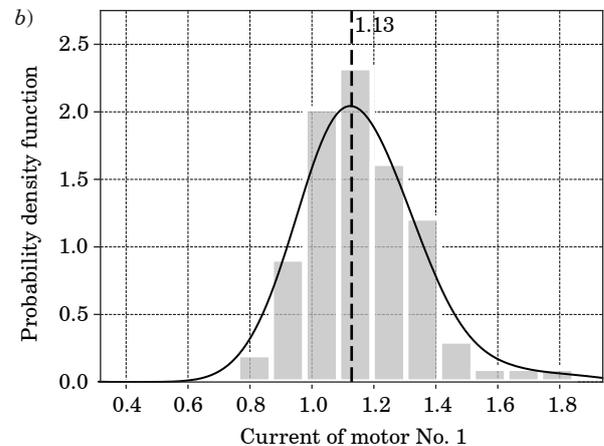
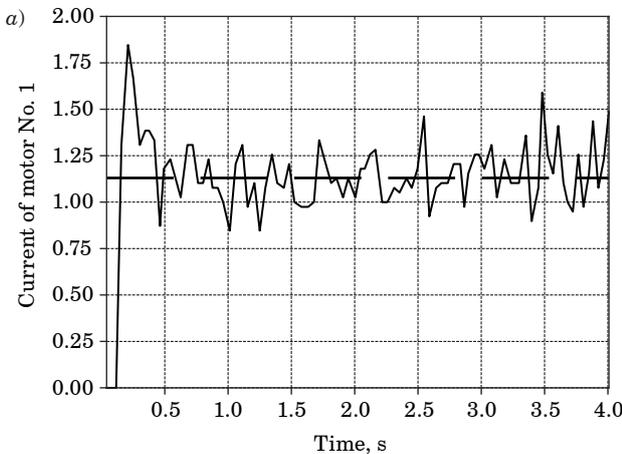
$$M = \frac{UI}{\omega}, \quad U = IR + C_e \omega,$$

where φ is the rotation angle of the robot's wheels ($\varphi = 30^\circ$); α is the rotation angle of the robot; r is the radius of the wheels ($r = 40$ mm); L is the distance from the center of the robot to the wheels; U is the motor voltage; I is the motor current; R is the motor winding resistance; C_e is the electrical coefficient of the motor.

Research methodology

At the beginning, data from a single experiment was analyzed. This analysis showed that in static operating mode, the momentary values fluctuate strongly. An example of motor current consumption values is shown in Fig. 2, *a*. Fluctuations arise due to measurement noise and weak homogeneity in the underlying surface of the same type. The analysis of the density of values indicates that the data distribution adheres to the bell curve (Fig. 2, *b*). This implies the necessity to analyze not momentary readings, but the distributions of values for different types of surfaces within one experiment. For easier analysis, the distributions will be presented in the form of box plots. For each experiment, boxes are plotted using the motor current values and all derived values described in the previous section for all types of surface.

In the box plots, we analyze the positions of median values, boundary intervals, their spread, and intersections with other boxes. The upper boundary of the interval corresponds to the value below which 75% of all data falls, known as the 75th percentile, while the lower boundary corresponds to the 25th percentile. Qualitative analysis of box plots showed that, for each type of motion, a specific parameter (such as motor currents, forces along axes, etc.) was most effective in distinguishing the surface. In particular, for motion along the X-axis in the local coordinates of the robot, the best possibilities for surface identification are giv-



■ **Fig. 2.** Value current of motor No. 1 when driving on a gray surface along the X-axis at a commanded velocity of 0.2 m/s: *a* – values against time; *b* – histogram and probability density function

en by currents of motor No. 1 and 3, current along the X-axis, and force along the X-axis (Fig. 3).

The next step is to quantitatively verify the conclusions derived from the qualitative analysis. For each experiment we evaluate the intersections of value intervals for all types of surfaces. First, we select the reference interval and label it as X. Next, we label as y the interval for the surface, which intersects a portion of X.

We identify possible interval locations in order to calculate quantitative representations of intersection.

A. The upper and lower bounds of one interval are above or below the corresponding bound of the other interval:

$$y \cap X = \begin{cases} \frac{X_{75} - y_{25}}{X_{75} - X_{25}} \cdot 100\%, & \text{if } y_{75} > X_{75}, y_{25} > X_{25}; \\ \frac{y_{75} - X_{25}}{X_{75} - X_{25}} \cdot 100\%, & \text{if } y_{75} < X_{75}, y_{25} < X_{25}. \end{cases}$$

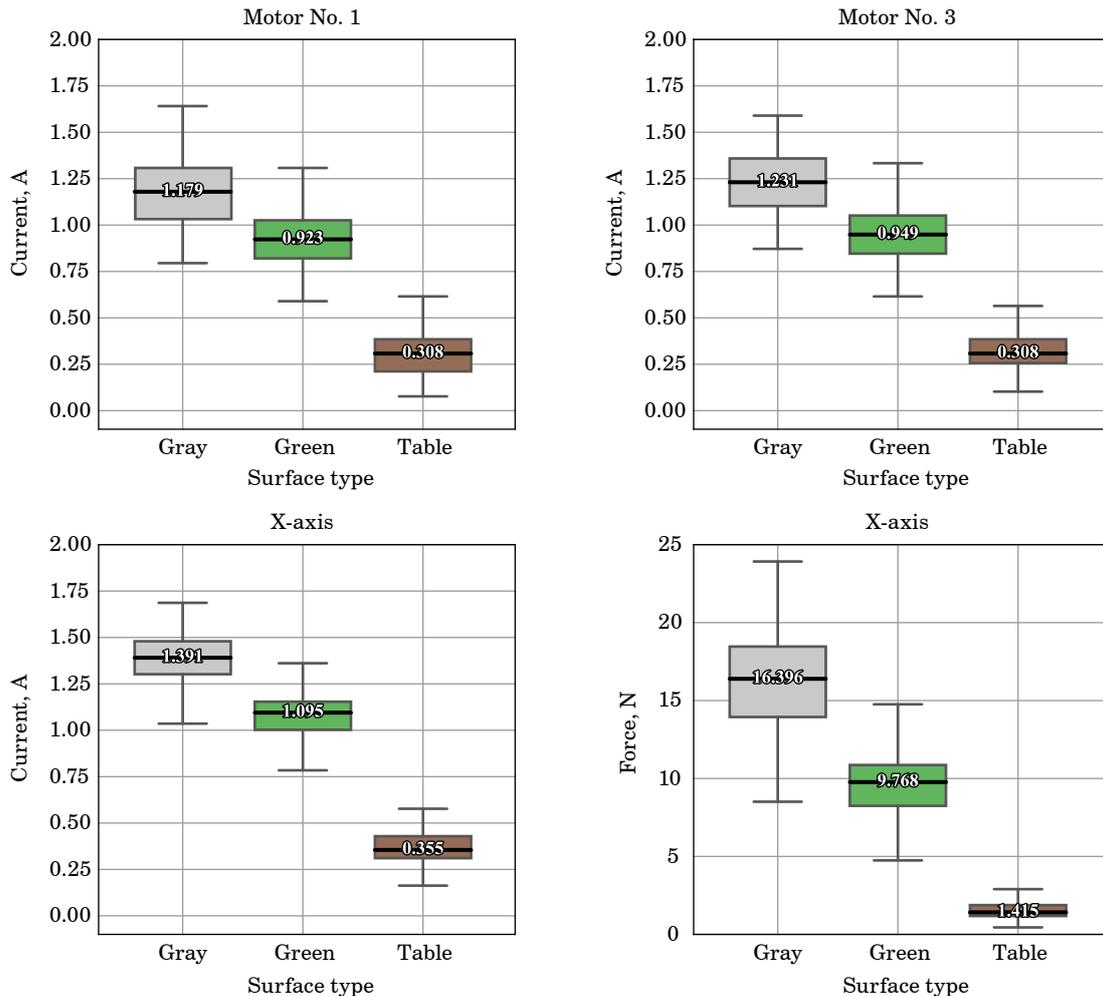
B. One of the intervals lies entirely within the boundaries of the other interval. The values are taken with a negative sign to distinguish them from the intersections of the first case:

$$y \cap X = \begin{cases} -\frac{X_{75} - y_{25}}{X_{75} - X_{25}} \cdot 100\%, & \text{if } y_{75} < X_{75}, y_{25} > X_{25}; \\ -100\%, & \text{if } y_{75} > X_{75}, y_{25} < X_{25}. \end{cases}$$

C. A value of 0% means that there is no intersection for this pair of surfaces, i. e. we can clearly distinguish them.

For the experiment, from which the data was previously used for box plots earlier (see Fig. 3), the derived numerical representations of the intersections are shown in Table 1.

Quantitative analysis of the range intersections for different parameters confirms the qualitative analysis and shows that the intersection values remain stable as the amplitude of the robot's velocity



■ Fig. 3. Box plots for currents of motor No. 1 and 3, current along the X-axis and force along the X-axis at a commanded velocity of 0.1 m/s

■ **Table 1.** Intersection values for movement along the X-axis for currents of motor No. 1 and 3, current along the X-axis and force along the X-axis

Amplitude	Current, %,									Force along the X-axis, %		
	of motor No. 1			of motor No. 3			along the X-axis					
	Green-gray	Table-green	Table-gray	Green-gray	Table-green	Table-gray	Green-gray	Table-green	Table-gray	Green-gray	Table-green	Table-gray
100	0	0	0	0	0	0	0	0	0	0	0	0
200	14	0	0	30	0	0	0	0	0	0	0	0
300	74	0	0	62	0	0	34	0	0	40	0	0

risers. The exception is the pair of two high power consuming green-gray surfaces, where an increase in amplitude results in an increase in the intersection value. Similar conclusions are obtained for other simple motion types, i. e., for motion along the Y-axis or for rotation.

The following conclusions were also drawn during the analysis.

1. For experiments where the velocity is multi-component, i.e. a combination of linear motions with the possible addition of rotational motion, the use of motor currents leads to better results in distinguishing between surfaces compared to the use of currents and forces along the axes. As a result, the motor current was chosen as the key parameter for the subsequent analysis.

2. It is worth selecting a motor with a greater impact in a particular type of motion in order to obtain better surface identification results by motor current consumption values. The experiments show that the motor impact depends on the direction of motion. It is derived from the kinematics of the robot.

3. In the ideal scenario, it would be advantageous to describe patterns for classifying surface types across all motion types investigated. However, with an increase in the number of directions and amplitudes of motion, the number of identified patterns will become excessively large. Also, the need to constantly explore new motion types makes the classifier inflexible. For these reasons, we group the motion types based on the principle of greater motor impact in the motion.

The main disadvantage of grouping experiments by motion type is the increased heterogeneity of the data compared to individual motions. This obviously leads to a loss of accuracy in surface classification. A major concern with this approach is the selection of an appropriate discretization step to form direction-based motion groups. It is clear that

reducing the step will lead to higher classification accuracy, but will force the developers to synthesize more rules to identify surfaces. The study favored maximum data aggregation by direction of motion. In each group, current values of one motor prevail over the others. Consequently, 13 motion groups are derived (including the rotational component). In our opinion, this number of groups represents the minimum requirement for adequate surface classification.

An example is provided in Table 2, that displays the median and standard deviation values of a current consumption calculated for the motor No. 3 by motion groups. The lines in bold are those for which the current sensor readings of the third motor show good separability. Derived data confirms the assumption that a particular motor prevails for identifying surfaces depending on the motion direction.

Figure 4 shows motor current box plots across all surfaces for each type of motion. The number of the motor that provides the most accurate distinguishing between surfaces for a given motion type is indicated above each plot. Thus, the figure shows the best dependencies for classifying surfaces in our case. It is observed that poor surface separability in particular motions is caused by the prevailing impact of the motor No. 2.

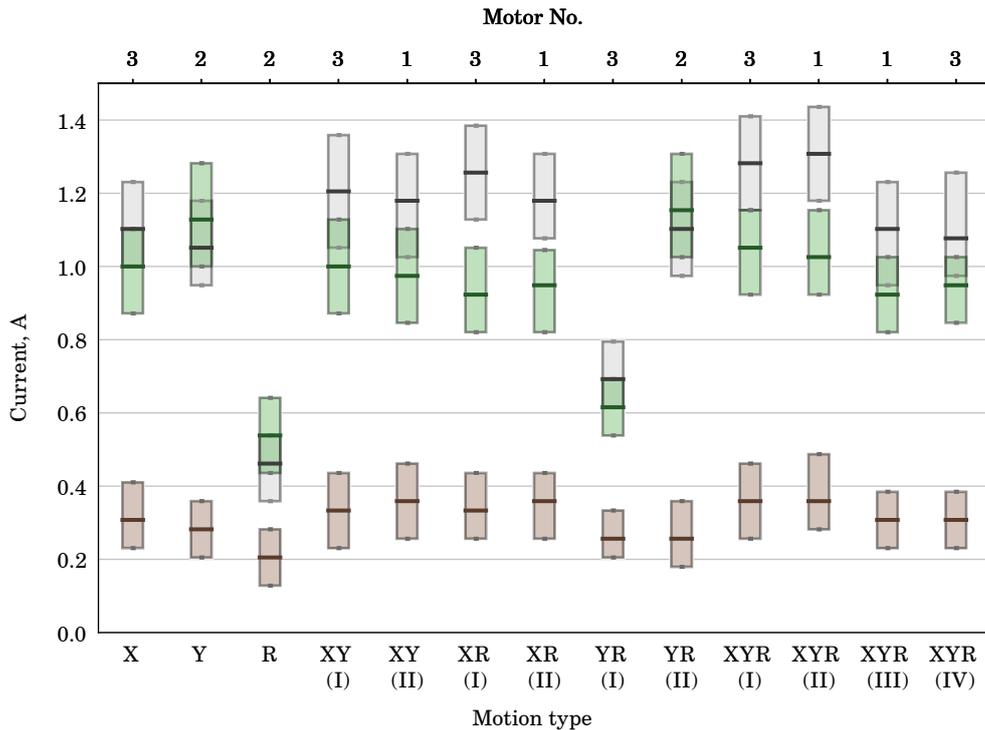
Considering all the analyses, we estimated a lower bound for the accuracy of surface classification based on the obtained patterns. For this purpose, the following formula was applied:

$$accuracy = \frac{1}{n_{dirs}} \sum_{i=1}^{n_{dirs}} \frac{1}{3} (\beta_{gray}^i + \beta_{green}^i + \beta_{table}^i),$$

where n_{dirs} – is the number of motion groups; β_x – accuracy of surface x , i. e. the part of the range of surface x that does not intersect with the ranges of the other surfaces.

■ **Table 2.** Median and standard deviation values of consumption current of motor No. 3 by motion groups

Direction in the local coordinates	Motion group	Current of motor No. 3						
		Gray		Green		Table		
		Mdn	σ	Mdn	σ	Mdn	σ	
X+, X-	X	1,103	0,039	1,000	0,032	0,308	0,018	
Y+, Y-	Y	0,564	0,022	0,615	0,017	0,256	0,013	
X+ Y+, X- Y-	XY (I)	1,205	0,053	1,000	0,047	0,333	0,034	
	X+ Y-, X- Y+	XY (II)	0,513	0,098	0,436	0,068	0,205	0,017
R+, R-	R	0,385	0,016	0,410	0,017	0,205	0,012	
X+ R+, X- R-	XR (I)	1,256	0,036	0,923	0,024	0,333	0,014	
	X+ R-, X- R+	XR (II)	0,923	0,163	0,795	0,155	0,231	0,024
Y+ R+, Y- R-	YR (I)	0,692	0,019	0,615	0,020	0,256	0,012	
	Y+ R-, Y- R+	YR (II)	0,026	0,004	0,077	0,006	0,000	0,007
X+ Y+ R+, X- Y- R-	XYR (I)	1,269	0,038	1,051	0,031	0,359	0,023	
	X- Y+ R+, X+ Y- R-	XYR (II)	0,128	0,009	0,051	0,009	0,026	0,007
	X- Y+ R-, X+ Y- R+	XYR (III)	0,487	0,018	0,462	0,017	0,205	0,016
	X- Y- R+, X+ Y+ R-	XYR (IV)	1,077	0,038	0,949	0,025	0,308	0,013



■ **Fig. 4.** Box plots of motor current on three surfaces depending on the direction of motion (color indicates surface types, gray and green accordingly surfaces title, brown for table)

$$\beta_x^i = 1 - \sum_y y_i \cap x_i.$$

In this case, the minimum classification accuracy is estimated to be 79.2%.

Fuzzy classifier

In this paper, fuzzy logic was used to solve the surface classification problem. Our decision was made based on the qualitative and quantitative

analysis of the intersection of motor current intervals across the surfaces, without considering the median value's position. We have chosen to use fuzzy logic because it offers several advantages in this case:

- easily handles data represented as sets;
- flexible rule generation for different motion types;
- based on the degree of membership of a particular value to a set which will help make use of median values later when forming sets;
- suitable for working with tasks that are not well formalized, for example, as in [25].

It is also convenient that the key objectives of implementing fuzzy logic have already been solved in the data analysis section. These objectives include creating input variable sets and formulating the algorithm rules.

In this paper, the Takagi – Sugeno fuzzy algorithm was chosen because it eliminates the need for deriving membership functions at the classifier's output. This choice is based on the specific classification task we addressed. The input of the classifier is the consumption current values of each robot's motor I_1 , I_2 , I_3 , the values of commanded X-axis speed, Y-axis speed, and commanded rotation speed ω . Numerical

velocity values do not play a role in the classification process. Rather, they function as logical variables in the classifier to identify the direction of motion. An example of input membership functions for motor current values is shown in Fig. 5.

In this case, the membership functions are constructed as Gaussians, because at the analysis stage the values from the current sensors within one experiment adhere to a normal distribution. The values of medians and standard deviations for the membership functions are taken from the data analysis section.

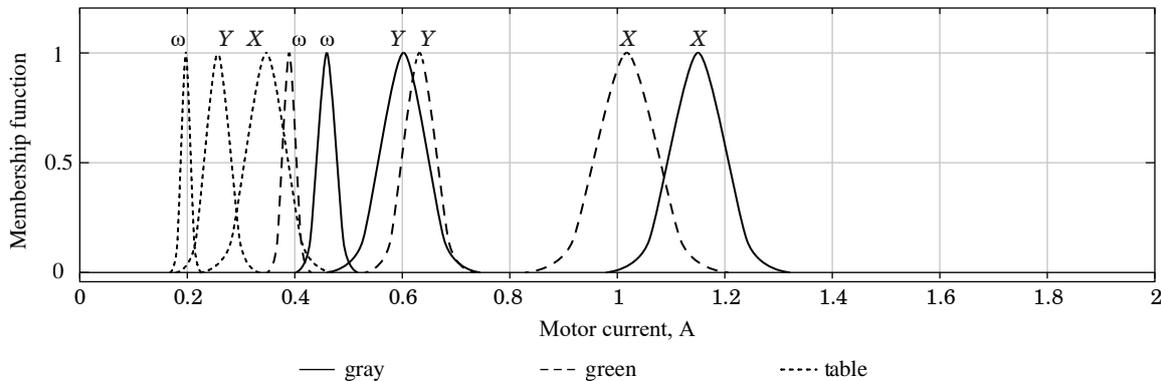
The classifier's output variable represents the degree of membership of motor current values to each surface, using a one-vs-all approach.

Evaluation of the fuzzy classifier

The evaluation of classifier accuracy is performed in two steps:

1. Testing the classifier on the original data that we used in the analysis phase to derive rules for distinguishing surface (*old data*).

2. Testing the classifier on separately gathered *new data*. New dataset contains more motion direc-



■ Fig. 5. Example of input membership functions of a fuzzy classifier

		Old data			New data		
		Gray	Green	Table	Gray	Green	Table
True labels	Gray	582	169	2	3343	1337	0
	Green	135	620	0	1000	3470	66
	Table	0	14	735	0	1	2519
		Predicted labels			Predicted labels		

■ Fig. 6. Confusion matrices for results obtained with the fuzzy classifier

tions and amplitudes compared to the *old data*. This test is necessary to evaluate the classifier's generalization in case of variable data.

Accuracy will be used as the key metric:

$$\text{accuracy} = \frac{\text{correct predictions}}{\text{all predictions}}$$

The accuracy on *old data* is expected to be higher than the previously estimated lower bound of 79.2%. The obtained accuracy on the two datasets is shown in the confusion matrices in Fig. 6.

As a result, the classifier showed an average accuracy of 85.8% (gray – 77.3%, green – 82.1%, table – 98.1%) on the *old data*. After switching to the *new data*, the accuracy dropped to 79.5% (gray – 77.0%, green – 72.2%, table – 97.4%). The most errors in both cases are made between the gray and green surfaces as the sensor system readings on these particular surfaces are partially similar in the process of a motion.

Machine learning

The performance of the fuzzy classifier is compared with machine learning models, which showed high quality of performance for the multiclass classification task.

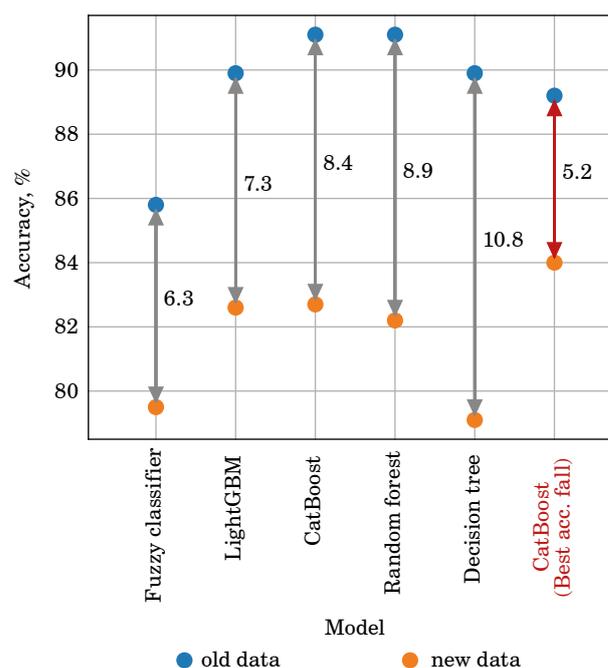
Based on a review [26] that identifies advantages, disadvantages, and applications of various machine learning methods used in classification tasks, we have chosen the following models that are balanced in terms of accuracy and learning speed: decision tree [27], random forest [28], LightGBM [29] and CatBoost [30]. All models are trained on the same data set that used to create the fuzzy classifier.

The algorithms are trained and validated on the initial set *old data*. Train – validation – test split ratio is 60–10–30%. Then, like a fuzzy classifier, the algorithms are tested on *new data*. The accuracy of the algorithm is evaluated similarly to that of the fuzzy classifier. During training on *old data*, hyperparameters are selected from the parameter grid based on the best accuracy criterion for each model. The accuracy score for hyperparameter tuning was calculated on train data using 5-fold cross-validation.

The results of the two-step tests are shown in Fig. 7. From the figure we can see that:

- The maximum accuracy of 91.1% on *old data* and the maximum accuracy of 82.7% on *new data* was shown by the gradient boosting algorithm CatBoost. Almost similar levels of accuracy are achieved with random forest.

- The fuzzy classifier shows the smallest accuracy fall of 6.3% between results for both data sets. This indicates its better generalization compared



■ **Fig. 7.** Results of classifier accuracy evaluation on two datasets

to machine learning algorithms tuned for the best accuracy.

- The accuracy fall in the range of 7 to 8%, comparable to the fuzzy classifier, appears only in the CatBoost and LightGBM boosting algorithms. Meanwhile, the average accuracy of the fuzzy logic based algorithms is lower by about 8% compared to the boosting algorithms, with a comparable accuracy fall. In other cases, an accuracy fall of over 8% is observed.

Similarly to tuning hyperparameters with the best accuracy criterion, machine learning algorithms are tuned for greater generalization in order to get a smaller accuracy fall when transitioning to *new data*. The CatBoost model achieved the best results at these hyperparameters, with an accuracy fall of only 5.2%.

Fuzzy logic – machine learning hybrid

The proposed fuzzy classifier, which is based on the identified patterns derived from analysis, demonstrates a generalization that is comparable to the best machine learning algorithm tuned for the same purpose. The reason for this is the design of input sets and rules derived from statistical information. Still, when compared to machine learning algorithms, its overall accuracy is lower because of a significant discretization step for grouping data based on motion direction. With precise tuning of the fuzzy classifier, the accuracy could be comparable to

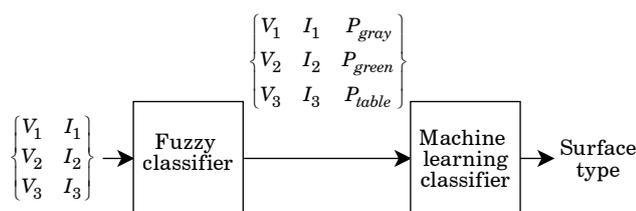
that of machine learning algorithms. However, the synthesis of a large number of rules would require a great deal of time. For instance, currently, the fuzzy classifier has 78 rules, while CatBoost tuned for the best accuracy has 1974 rules.

We suggest a solution to use the outputs of the proposed fuzzy classifier as feature inputs for machine learning algorithms. We aim to achieve more precise tuning of the fuzzy classifier while preserving its simplicity and generalization. The structure of the proposed hybrid solution is shown in Fig. 8.

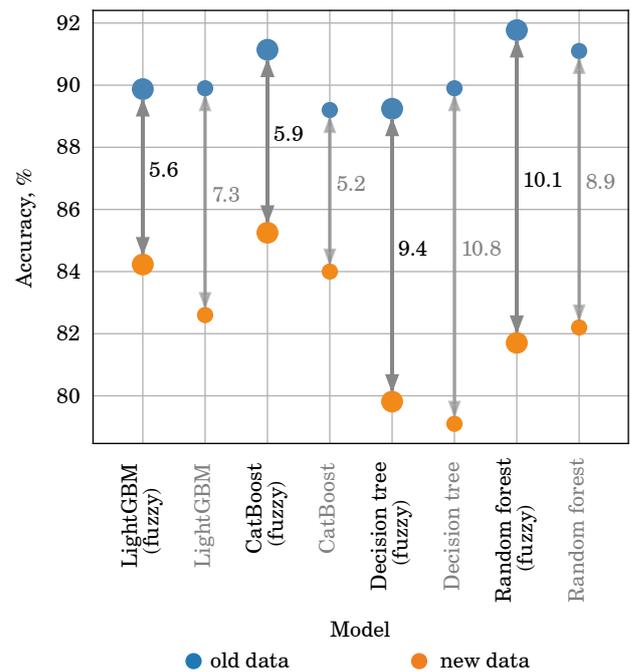
For the hybrid algorithm, we trained the same machine learning methods used in the previous stage.

The results of testing the cascade on two datasets and comparing them to methods without fusion with fuzzy logic are shown in Fig. 9. It can be observed that the addition of fuzzy logic as input features gives inconsistent results. It can either increase or decrease the accuracy fall and the average accuracy on different datasets. The best effect is achieved for a hybrid of fuzzy logic and CatBoost. The average classification accuracy increased on both datasets, resulting in a reduction of the accuracy fall compared to the original fuzzy classifier. In comparison with CatBoost, the proposed algorithm showed on *old data* an accuracy comparable to the best accuracy tuning 91.1% (gray – 86.0%, green – 82.6%, table – 100.0%) and an accuracy drop comparable to the best generalization tuning with difference 0.7%. As a result, the proposed hybrid method gave the maximum accuracy on *new data* 85.2% (gray – 83.6%, green – 79.5%, table – 98.9%). Also, the number of rules of the final classifier decreased to 980.

It was confirmed that the output values of the fuzzy classifier are the main parameters that CatBoost uses for surface recognition. For complex gray and green surface types, the fuzzy classifier values are prioritized in CatBoost. Decision tree structure analyses in CatBoost reveal the prioritization of fuzzy classifier outputs as features at first layers in the trees (1–2 layer). In addition, the *feature importance* metric of CatBoost model showed the following feature priority: fuzzy classifier output for gray surface (23.72%), fuzzy classifier output



■ Fig. 8. Fuzzy logic – machine learning hybrid structure



■ Fig. 9. Results of hybrid method accuracy evaluation on two data sets

for green surface (20.01%), consumption current of motor No. 3 (17.36%), consumption current of motor No. 1 (16.47%), consumption current of motor No. 2 (13.83%), fuzzy classifier output for table (8.60%).

This set of feature importances confirms the significance of the fuzzy classifier outputs, and also indicates that the model uses motor current values to adjust the final result, thus increasing the average accuracy.

Conclusion

The research carried out on resolving the surface classification issue, using an omnidirectional robot as an example, allows us to draw several conclusions. The analysis of complex multi-component motion types has shown that the best distinguishing between surfaces is achieved by using the motor current values. In this case, it is more appropriate to classify the surfaces based on the readings from the current sensor of the motor with the most impact in the motion process. The impact of the motor derives from the robot kinematics and the selected direction of motion.

During the preparation phase for the classifier implementation, it became evident that the fuzzy logic principles complement the performed analysis of sensor value distribution, including their median and standard deviation values. The quantitative analysis of the values' intersection proves the qual-

itative analysis and allows us to assess the classifier's lower limit of accuracy at 79.2%.

The fuzzy classifier is synthesized on data that was grouped according to the criterion of the most impactful motor in a selected direction of motion. This approach reduces a number of fuzzy logic rules. The classifier is subsequently tested on the original (*old data*) and extended (*new data*) data sets. The accuracy is estimated to be 85.8 and 79.5% respectively, with an accuracy fall of 6.3%. The fuzzy classifier is then compared with machine learning methods. In most cases, machine learning algorithms outperform the fuzzy classifier in terms of average accuracy, but loses out in terms of accuracy fall.

In this paper, we propose a fuzzy logic – machine learning cascade in order to preserve the generalization of the fuzzy classifier and improve the accuracy of surface detection by considering more patterns using machine learning methods. The best results are achieved by the hybrid of CatBoost and fuzzy logic. It shows 91.1% accuracy on *old data* and 85.2% on *new data* with a 5.9% accuracy fall. This is the best classification result among all tested methods.

The proposed method for analyzing and classifying data allows us to distinguish between surfaces with different power consumption (gray and table). Moreover, the classifier demonstrates high accuracy in identifying surfaces with similar power consumption levels that are formed due to different surface properties (gray – softness, green – topography).

Compared to [10], the obtained surface classification accuracy on the new data of 85.2% is higher than the average classification accuracy for all surfaces of 56.9% when using only information from motor currents.

The proposed classifier demonstrated comparable classification accuracy on the training data (*old data*) (gray – 86.0%, green – 82.6%, table – 100%) to the classifier in [21] (gray – 82.1%, green –

88.0%, table – 97.0%). In [21], the authors used an extended vector of sensory information for the classifier, including robot velocities, accelerometer, and gyroscope data. The robot and the underlying surfaces are similar in both cases.

Discussion

Surface classification with subsequent extraction of information about the properties of the surface is one of the main priority tasks for outdoor robots. However, for most local navigation tasks this problem is solved by conducting a preliminary surface analysis and creating a classifier based on the obtained data. This paper raises the problem of a lack of universally applicable approach for solving the classification problem. In continuation, we will focus on the versatility of solving the classification problem based on the proposed data analysis and the classifier construction technique.

Firstly, further research will focus on the possibility of transitioning to a single value that describes the energy cost of motion. This value depends on the kinematics of a mobile robot, direction of motion, rotation speed amplitude, and other relevant parameters. We believe a universal parameter will reduce a number of input features in the classifier.

Secondly, we plan to explore the classification of surfaces across a full range of motor currents or the power consumption parameter. This involves generating new sets and rules for the classifier as the robot navigates, and adapting existing sets and rules to changes in the external environment. Real-time modifications to the classifier will make it a universal solution to the problem of distinguishing between surface types.

Lastly, as this work concentrates on analyzing only the direct power consumption of motion, further research will use additional information to expand the understanding of surfaces' physical properties.

References

1. Liu C., Fang J., Liu Y., Lu Y. The field terrain recognition based on extreme learning machine using wavelet features. *2017 IEEE Intern. Conf. on Mechatronics and Automation*, 2017, pp. 1947–1951. doi:10.1109/ICMA.2017.8016116
2. Brooks C. A., Iagnemma K. D. Self-supervised classification for planetary rover terrain sensing. *2007 IEEE Aerospace Conf.*, Big Sky, MT, USA, 2007, pp. 1–9. doi:10.1109/AERO.2007.352693
3. Chen Y., Rastogi C., Norris W. R. A CNN based vision-proprioception fusion method for robust ugv terrain classification. *IEEE Robotics and Automation Letters*, 2021, vol. 6, iss. 4, pp. 7965–7972. doi:10.1109/LRA.2021.3101866
4. Guan T., Song R., Ye Z., Zhang L. Vinet: Visual and inertial-based terrain classification and adaptive navigation over unknown terrain. *2023 IEEE Intern. Conf. on Robotics and Automation*, 2023, pp. 4106–4112. doi:10.1109/ICRA48891.2023.10161251
5. Zürn J., Burgard W., Valada A. Self-supervised visual terrain classification from unsupervised acoustic feature learning. *IEEE Transactions on Robotics*, 2020, vol. 37, iss. 2, pp. 466–481. doi:10.1109/TRO.2020.3031214
6. Xue F., Hu L., Yao C., Liu Z., Zhu Z., Jia Z. Sound-based terrain classification for multi-modal wheel-leg

- robots. *2022 Intern. Conf. on Advanced Robotics and Mechatronics*, Guilin, China, 2022, pp. 174–179. doi:10.1109/ICARM54641.2022.9959511
7. **Brooks C., Iagnemma K., Dubowsky S.** Vibration-based terrain analysis for mobile robots. *2005 IEEE Intern. Conf. on Robotics and Automation*, Barcelona, Spain, 2005, pp. 3415–3420. doi:10.1109/ROBOT.2005.1570638
 8. **Csik D., Odry Á., Sárosi J., Sarcevic P.** Inertial sensor-based outdoor terrain classification for wheeled mobile robots. *2021 IEEE 19th Intern. Symp. on Intelligent Systems and Informatics*, Subotica, Serbia, 2021, pp. 159–164. doi:10.1109/SISY52375.2021.9582504
 9. **Dupont E. M., Moore C. A., Collins E. G., Coyle E.** Frequency response method for terrain classification in autonomous ground vehicles. *Autonomous Robots*, 2008, vol. 24, pp. 337–347. doi:10.1007/s10514-007-9077-0
 10. **Ojeda L., Borenstein J., Witus G., Karlsen R.** Terrain characterization and classification with a mobile robot. *Journal of Field Robotics*, 2006, vol. 23, iss. 2, pp. 103–122. doi:10.1002/rob.20113
 11. **Yu Z., Sadati S. H., Hauser H., Childs P. R., Nanayakkara T.** A semi-supervised reservoir computing system based on tapered whisker for mobile robot terrain identification and roughness estimation. *IEEE Robotics and Automation Letters*, 2022, vol. 7, iss. 2, pp. 5655–5662. doi:10.1109/LRA.2022.3159859
 12. **Riopelle N., Caspers P., Sofge D.** Terrain classification for autonomous vehicles using bat-inspired echolocation. *2018 Intern. Joint Conf. on Neural Networks*, 2018, pp. 1–6. doi:10.1109/IJCNN.2018.8489046
 13. **Bednarek M., Łysakowski M., Bednarek J., Nowicki M. R., Walas K.** Fast haptic terrain classification for legged robots using transformer. *2021 European Conf. on Mobile Robots*, Bonn, Germany, 2021, pp. 1–7. doi:10.1109/ECMR50962.2021.9568808
 14. **Bednarek J., Bednarek M., Wellhausen L., Hutter M., Walas K.** What am I touching? Learning to classify terrain via haptic sensing. *2019 Intern. Conf. on Robotics and Automation*, 2019, pp. 7187–7193. doi:10.1109/ICRA.2019.8794478
 15. **Ding L., Xu P., Li Z., Zhou R., Gao H., Deng Z., Liu G.** Pressing and rubbing: physics-informed features facilitate haptic terrain classification for legged robots. *IEEE Robotics and Automation Letters*, 2022, vol. 7, iss. 3, pp. 5990–5997. doi:10.1109/LRA.2022.3160833
 16. **Wu X. A., Huh T. M., Sabin A., Suresh S. A., Cutkosky M. R.** Tactile sensing and terrain-based gait control for small legged robots. *IEEE Transactions on Robotics*, 2019, vol. 36, iss. 1, pp. 15–27. doi:10.1109/TRO.2019.2935336
 17. **Iagnemma K., Brooks C., Dubowsky S.** Visual, tactile, and vibration-based terrain analysis for planetary rovers. *2004 IEEE Aerospace Conf. Proc.*, Big Sky, MT, USA, 2004, pp. 841–848. doi:10.1109/AERO.2004.1367684
 18. **Iagnemma K., Kang S., Shibly H., Dubowsky S.** On-line terrain parameter estimation for wheeled mobile robots with application to planetary rovers. *IEEE Transactions on Robotics*, 2004, vol. 20, iss. 5, pp. 921–927. doi:10.1109/TRO.2004.829462
 19. **Yuan Y., Yang H., Yang C., Ding L., Gao H., Li N.** Multi-slip conditions acquisition of planetary rovers with application to terrain parameter identification. *2021 27th Intern. Conf. on Mechatronics and Machine Vision in Practice*, Shanghai, China, 2021, pp. 60–65. doi:10.1109/M2VIP49856.2021.9665041
 20. **Reina G., Ojeda L., Milella A., Borenstein J.** Wheel slippage and sinkage detection for planetary rovers. *IEEE/Asme Transactions on Mechatronics*, 2006, vol. 11, iss. 2, pp. 185–195. doi:10.1109/TMECH.2006.871095
 21. **Andrakhonov A., Belyaev A.** GMDH-based learning system for mobile robot navigation in heterogeneous environment. *Advances in Intelligent Systems and Computing II: Selected Papers from the Intern. Conf. on Computer Science and Information Technologies*, Lviv, Ukraine, 2018, pp. 1–20. doi:10.1007/978-3-319-70581-1_1
 22. **Odedra S.** Using unmanned ground vehicle performance measurements as a unique method of terrain classification. *2011 IEEE/RSJ Intern. Conf. on Intelligent Robots and Systems*, 2011, pp. 286–291. doi:10.1109/IROS.2011.6048732
 23. **Belyaev A. S., Brylev O. A., Ivanov E. A.** Slip detection and compensation system for mobile robot in heterogeneous environment. *IFAC-PapersOnLine*, 2021, vol. 54, iss. 13, pp. 339–344. doi:10.1016/j.ifacol.2021.10.470
 24. **Andrakhonov A., Belyaev A.** Navigation learning system for mobile robot in heterogeneous environment: Inductive modeling approach. *2017 12th Intern. Scient. and Tech. Conf. on Computer Sciences and Information Technologies*, Lviv, Ukraine, 2017, pp. 543–548. doi:10.1109/STC-CSIT.2017.8098846
 25. **Serobabov A. S., Denisova L. A.** Development of a medical expert system: disease staging by a fuzzy classifier. *Journal of Physics: Conference Series*, 2022, vol. 2182, no. 1, p. 012030. doi:10.1088/1742-6596/2182/1/012030
 26. **Singh A., Thakur N., Sharma A.** A review of supervised machine learning algorithms. *2016 3rd Intern. Conf. on Computing for Sustainable Global Development*, 2016, pp. 1310–1315.
 27. **Swain P. H., Hauska H.** The decision tree classifier: Design and potential. *IEEE Transactions on Geoscience Electronics*, 1977, vol. 15, iss. 3, pp. 142–147. doi:10.1109/TGE.1977.6498972
 28. **Biau G., Scornet E.** A random forest guided tour. *Test*, 2016, vol. 25, pp. 197–227. doi:10.1007/s11749-016-0481-7
 29. **Ke G., Meng Q., Finley T., Wang T., Chen W., Ma W., Ye Q., Liu T.-Y.** LightGBM: A highly efficient gradient

boosting decision tree. *31st Conf. on Neural Information Processing Systems (NIPS 2017)*, Long Beach, CA, USA, 2017, pp. 1–9.

30. Prokhorenkova L., Gusev G., Vorobev A., Dorogush A. V., Gulin A. CatBoost: unbiased boosting

with categorical features. *Advances in Neural Information Processing Systems*, 2018, 31. doi:10.48550/arXiv.1706.09516

УДК 007.52:004.896:51-74

doi:10.31799/1684-8853-2024-1-31-43

EDN: WPZYLY

Синтез гибридного классификатора подстилающих поверхностей на основе нечеткой логики с использованием токовых энергозатрат движения мобильного робота

А. С. Беляев^а, канд. техн. наук, старший преподаватель, orcid.org/0000-0002-0725-4690, asb22@tpu.ru

О. Ю. Кушнарев^а, магистрант, orcid.org/0009-0004-6793-0162

О. А. Брылев^а, инженер-программист, orcid.org/0009-0006-8512-2518

^аНациональный исследовательский Томский политехнический университет, Ленина пр., 30, Томск, 634050, РФ

Введение: одним из подходов при решении задач навигации и управления мобильными роботами, работающими на открытом воздухе, является использование классификации типа подстилающих поверхностей, по которым перемещается робот в реальном времени. Знания о типе подстилающей поверхности позволяют использовать ранее известные характеристики поверхностей для улучшения точности локализации и алгоритмов управления. **Цель:** исследовать применимость данных об энергозатратах движения для решения задачи классификации поверхностей с различными физическими свойствами для робота со сложной кинематикой. **Результаты:** анализ многокомпонентных типов движения всенаправленного робота показал, что лучшая разделяемость поверхностей достигается при использовании значений токов двигателей. При этом классификацию поверхностей целесообразнее осуществлять по значениям тока двигателя, наиболее влияющего на процесс движения. Нечеткий классификатор синтезирован на основе данных, сгруппированных по критерию наиболее влияющего на выбранное направление движения двигателя. Проведено сравнение нечеткого классификатора с методами машинного обучения. Предложен каскад нечеткая логика — машинное обучение с целью сохранить обобщающую способность нечеткого классификатора и улучшить точность определения поверхностей через учет большего количества закономерностей с помощью методов машинного обучения. Предложенная методика анализа данных и метод классификации позволяют с высокой точностью разделять поверхности, отличающиеся по энергозатратам, в том числе сформированным за счет разных параметров поверхности. **Практическая значимость:** результаты исследований могут быть использованы как для создания самостоятельного классификатора поверхностей, так и в рамках комплексного классификатора с использованием разных видов входной информации.

Ключевые слова — классификация подстилающих поверхностей, гибридные методы, машинное обучение, нечеткая логика, деревья решений, градиентный бустинг, мобильная робототехника, анализ токов потребления.

Для цитирования: Belyaev A. S., Kushnarev O. Yu., Brylev O. A. Synthesis of a hybrid underlying surface classifier based on fuzzy logic using current consumption of mobile robot motion. *Информационно-управляющие системы*, 2024, № 1, с. 31–43. doi:10.31799/1684-8853-2024-1-31-43, EDN: WPZYLY

For citation: Belyaev A. S., Kushnarev O. Yu., Brylev O. A. Synthesis of a hybrid underlying surface classifier based on fuzzy logic using current consumption of mobile robot motion. *Informatsionno-upravliaushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 31–43. doi:10.31799/1684-8853-2024-1-31-43, EDN: WPZYLY



Методика повышения защищенности сети передачи данных объектов критической информационной инфраструктуры при многоэтапных атаках

В. А. Липатников^а, доктор техн. наук, профессор, старший научный сотрудник, orcid.org/0000-0002-3736-4743, lipatnikovanl@mail.ru

А. А. Шевченко^а, канд. техн. наук, старший научный сотрудник, orcid.org/0000-0001-9113-1089

К. В. Мелехов^а, адъюнкт, orcid.org/0009-0007-3474-412X

Д. Ф. Ткачев^а, канд. техн. наук, начальник отдела, orcid.org/0009-0004-2256-9270

^аВоенная академия связи им. Маршала Советского Союза С. М. Буденного, Тихорецкий пр., 3, Санкт-Петербург, 194064, РФ

Введение: стремительное развитие информационных технологий приводит к появлению новых угроз и уязвимостей в информационных системах в различных областях жизни общества, эксплуатация которых увеличивает вероятность успешной атаки злоумышленника. В связи с этим возникает необходимость исследовать методы повышения защищенности сетей передачи данных в условиях многоэтапных атак. **Цель:** повысить защищенность сети передачи данных путем проактивного управления безопасностью при многоэтапных атаках. **Результат:** разработана методика повышения защищенности сетей передачи данных при многоэтапных атаках на основе проактивного управления безопасностью. Методика включает в себя превентивный анализ динамики нарушителей, выявление несоответствий политики безопасности, определение параметров аномалий сетевого трафика, классификацию типов атак и определение геолокации нарушителей. Процесс обеспечения безопасности сети передачи данных был формализован с использованием математического аппарата теории марковских процессов с дискретными состояниями и непрерывным временем, что позволило получить зависимости вероятности обеспечения безопасности сети передачи данных от времени протекания различных подпроцессов системы информационной безопасности в наглядном графическом виде. Результаты моделирования показали, что предложенная методика позволяет повысить вероятность обеспечения безопасности сети передачи данных в течение заданного времени и, следовательно, создает условия для своевременного предоставления конечным пользователям услуг по обеспечению качества сети передачи данных. **Практическая значимость:** методика является математической основой системы информационной безопасности, учитывающей параметры процессов воздействия и защиты для принятия эффективных мер по парированию многоэтапных атак с использованием машинного обучения. Результаты исследования могут быть применимы при разработке или устранении неисправностей в системах информационной безопасности сетей передачи данных объектов критической информационной инфраструктуры.

Ключевые слова — проактивное управление, сеть передачи данных, многоэтапная атака, объект критической информационной инфраструктуры, метод машинного обучения, геолокация, информационная безопасность, аномалии, сетевой трафик.

Для цитирования: Липатников В. А., Шевченко А. А., Мелехов К. В., Ткачев Д. Ф. Методика повышения защищенности сети передачи данных объектов критической информационной инфраструктуры при многоэтапных атаках. *Информационно-управляющие системы*, 2024, № 1, с. 44–55. doi:10.31799/1684-8853-2024-1-44-55, EDN: MVWIFR

For citation: Lipatnikov V. A., Shevchenko A. A., Melekhov K. V., Tkachev D. F. Methodology for improving the security of the data transmission network of critical information infrastructure objects under multi-stage attacks. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 44–55 (In Russian). doi:10.31799/1684-8853-2024-1-44-55, EDN: MVWIFR

Введение

В современных условиях геополитической нестабильности обеспечение безопасности объектов критической информационной инфраструктуры (КИИ), а именно информационных систем и в частности сетей передачи данных (СПД; Data Transmission Network – DTN), является актуальным направлением [1], которое включает в себя развитие методик повышения защищенности СПД от многоэтапных атак (МЭА; Multi-Stage Attack – MSA). Развитие IT-технологий и постоянный рост количества пользователей и аппаратных мощностей информационных систем приводит к неконтролируемому появлению

новых уязвимостей в них, которые позволяют нарушителю получать доступ к СПД КИИ, сканировать ресурсы сети, повышать права доступа в атакуемом сегменте сети, внедрять скрипты, удаленно подключаться к оборудованию СПД и выключать его, искать конфиденциальную информацию, блокировать учетные записи пользователей [2, 3].

Воздействие МЭА приводит к повышению в СПД нелегитимной активности [4], которая влечет за собой изменение в пропускной способности телекоммуникационного оборудования (ТКО) СПД, задержки в каналах связи и потери кадров при передаче информации по СПД. Одновременно с этим при организации непрерывного и опера-

тивного контроля и обнаружения аномалий в трафике СПД появляются проблемы, связанные со сложной маршрутизацией потоков информации в СПД объектов КИИ. С другой стороны, СПД в данных условиях должна функционировать без сбоев и предоставлять качественные услуги конечным пользователям. Выявленные противоречия дают толчок для развития научно-методического аппарата обнаружения и прогнозирования МЭА, основанного на современных интеллектуальных технологиях, к числу которых можно отнести машинное обучение и анализ.

В работах [5–7] представлены способы, в которых делается акцент на управление информационной безопасностью (ИБ) инфраструктуры на основе выявления уязвимостей в процессе функционирования. В данных источниках управление ИБ является реактивным, так как не подразумевается прогнозирование развития атаки на сеть. Это позволяет сделать вывод, что вновь разрабатываемые способы и методики управления ИБ должны быть направлены на анализ не только динамики действий нарушителя, но и содержания блоков данных протоколов по этапам атаки. Наряду с этим одним из требований к управлению ИБ СПД является реализация способов контроля защищенности в режиме времени, близком к реальному. Отсюда вытекает противоречие между интенсивно развивающимися способами воздействия на СПД и их реализующими возможностями, с одной стороны, и применяемыми методами управления ИБ — с другой. Таким образом, необходимость оценки защищенности СПД объектов КИИ оказывается актуальной.

Целью данного исследования является повышение вероятности защищенности СПД в течение заданного времени на основе методики проактивного управления безопасностью при реализации противником МЭА. Проактивный характер управления безопасностью заключается в принятии решения по защите от МЭА на основе данных прогноза, действий нарушителя с учетом модели МЭА.

Задачей исследования является разработка методики повышения защищенности СПД при МЭА, основанной на прогнозировании стратегии вторжения нарушителя за счет применения интеллектуальных технологий.

Методика повышения защищенности СПД при МЭА

Структура СПД как объекта воздействия МЭА представлена на рис. 1.

Предполагаемая методика включает в себя взаимосвязанную последовательность подпроцессов, а именно содержит действия:

- превентивного анализа динамики действий нарушителя;
- обнаружения несоответствий политики безопасности;
- определения параметров аномалий сетевого трафика;
- классификации видов атак и получения полной информации;
- установления геолокации нарушителя [8, 9].

Методика управления защищенностью СПД при МЭА представлена в виде алгоритма (рис. 2). Алгоритм процесса функционирования системы информационной безопасности (СИБ; Information System Security – ISS) СПД при МЭА описывает полную последовательность подпроцессов управления СИБ СПД за один цикл.

В соответствии с отраслевыми нормативными документами прежде чем СИБ начнет функционировать в штатном режиме, СПД и СИБ вводят в эксплуатацию, что и было учтено в предлагаемом алгоритме.

Управление СИБ начинается с формирования исходных данных, а именно вырабатываются модели функционально-логической архитектуры СПД и используемых в СПД сетевых протоколов. Также весь входящий трафик представляется в виде модели цифрового потока.

Модель цифрового потока (N)-соединения ((N) -ЦПС) СПД есть определенная на периоде существования соединения алгебраическая система

$$A = \langle S, \{\oplus\}, \{R\} \rangle, \quad (1)$$

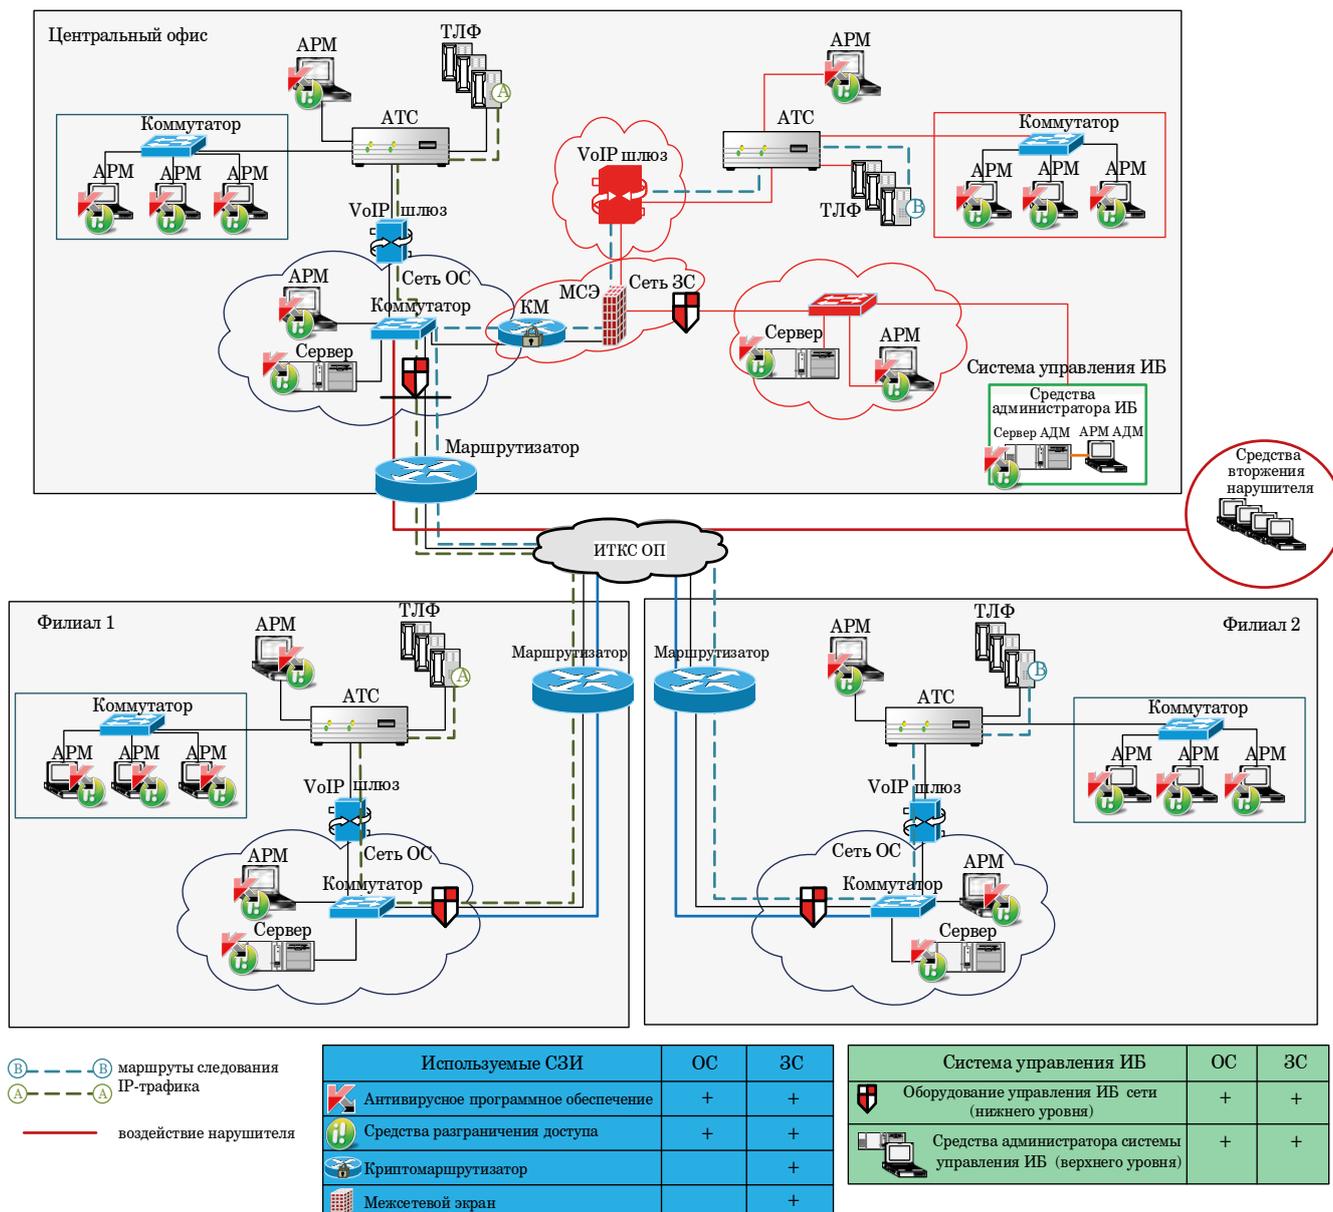
где S – множество структурных элементов (N)-ЦПС; \oplus – операция конкатенации на множестве структурных элементов; R – бинарное отношение на множестве структурных элементов в (N)-ЦПС.

Модель в виде структуры (N)-ЦПС СПД, описываемого алгеброй вида (1), есть отношение строгого порядка, определенное на множестве структурных элементов и существующее на интервале, равном длительности существования соединения, т. е.

$$R = \{\forall (s_i, s_j, s_k) \in S, s_i R s_j \neq s_j R s_i, i \leq j; \\ s_i R s_j \wedge s_j R s_k \rightarrow s_i R s_k, i < j < k\}, \quad (2)$$

где s_i, s_j, s_k – структурные элементы (N)-ЦПС канального уровня.

В устройстве поиска информации [10, 11] на основе модели (цифрового потока) обеспечивается более высокая вероятность правильного распознавания информационного цифрового потока.



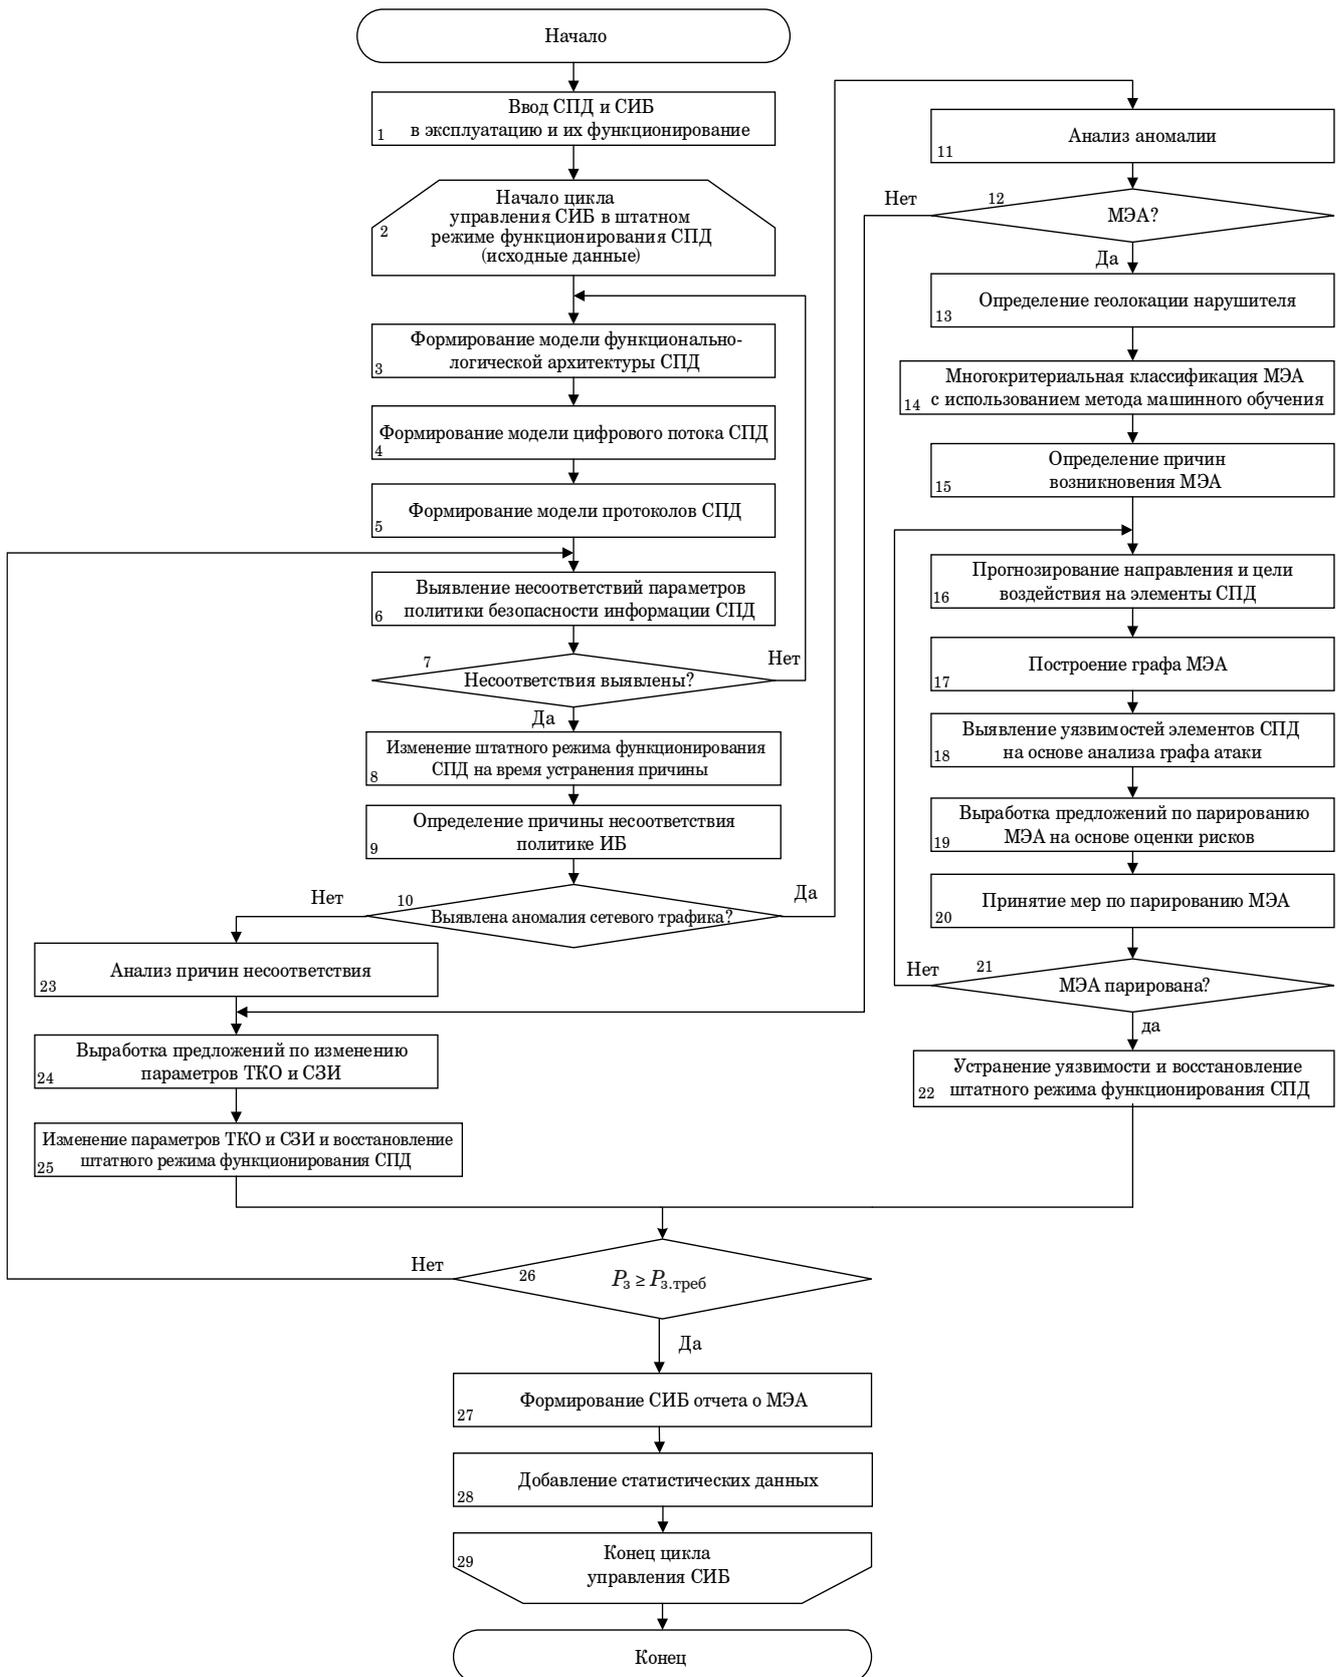
■ **Рис. 1.** Структура СПД как объекта воздействия МЭА: АРМ – автоматизированное рабочее место; ТЛФ – телефон; АТС – автоматическая телефонная станция; сеть ОС – сеть открытого сегмента; сеть ЗС – сеть закрытого сегмента; КМ – криптомаршрутизатор; МСЭ – межсетевой экран; АДМ – администратор; ИТКС ОП – информационно-телекоммуникационная сеть общего пользования; СЗИ – средства защиты информации

■ **Fig. 1.** Structure of DTN as an object of MSA impact: АРМ – automated workstation; ТЛФ – telephone; АТС – automatic telephone exchange; сеть ОС – open segment network; сеть ЗС – closed segment network; КМ – crypto router; МСЭ – firewall; АДМ – administrator; ИТКС ОП – public information and telecommunications network; СЗИ – information security tools

Далее в автоматическом режиме выявляются несоответствия параметров политики безопасности. В случае если несоответствия выявлены, то изменяется штатное функционирование СПД на время определения и устранения выявленных угроз. В результате установления причин несоответствия политики безопасности может быть определено, что триггером является аномалия сетевого трафика, которую необходимо под-

вергнуть анализу. Если выявится факт МЭА, то необходимо выполнить следующие действия:

- установить геолокацию нарушителя [12, 13];
- провести классификацию воздействия (данный процесс возможно реализовать методом машинного обучения);
- спрогнозировать тактику нарушителя и цель воздействия;
- на основе прогноза построить граф атаки;



■ **Рис. 2.** Алгоритм функционирования СИБ СПД при МЭА
 ■ **Fig. 2.** Algorithm of functioning of the ISS of DTN under the MSA

– определить уязвимости СПД, через которую нарушитель реализует МЭА [14, 15];

– с учетом оценки рисков выработать конкретные предложения по парированию МЭА и реализовать их.

Вышеописанные процессы могут быть реализованы в автоматическом или ручном режиме и позволят восстановить штатный режим функционирования СПД.

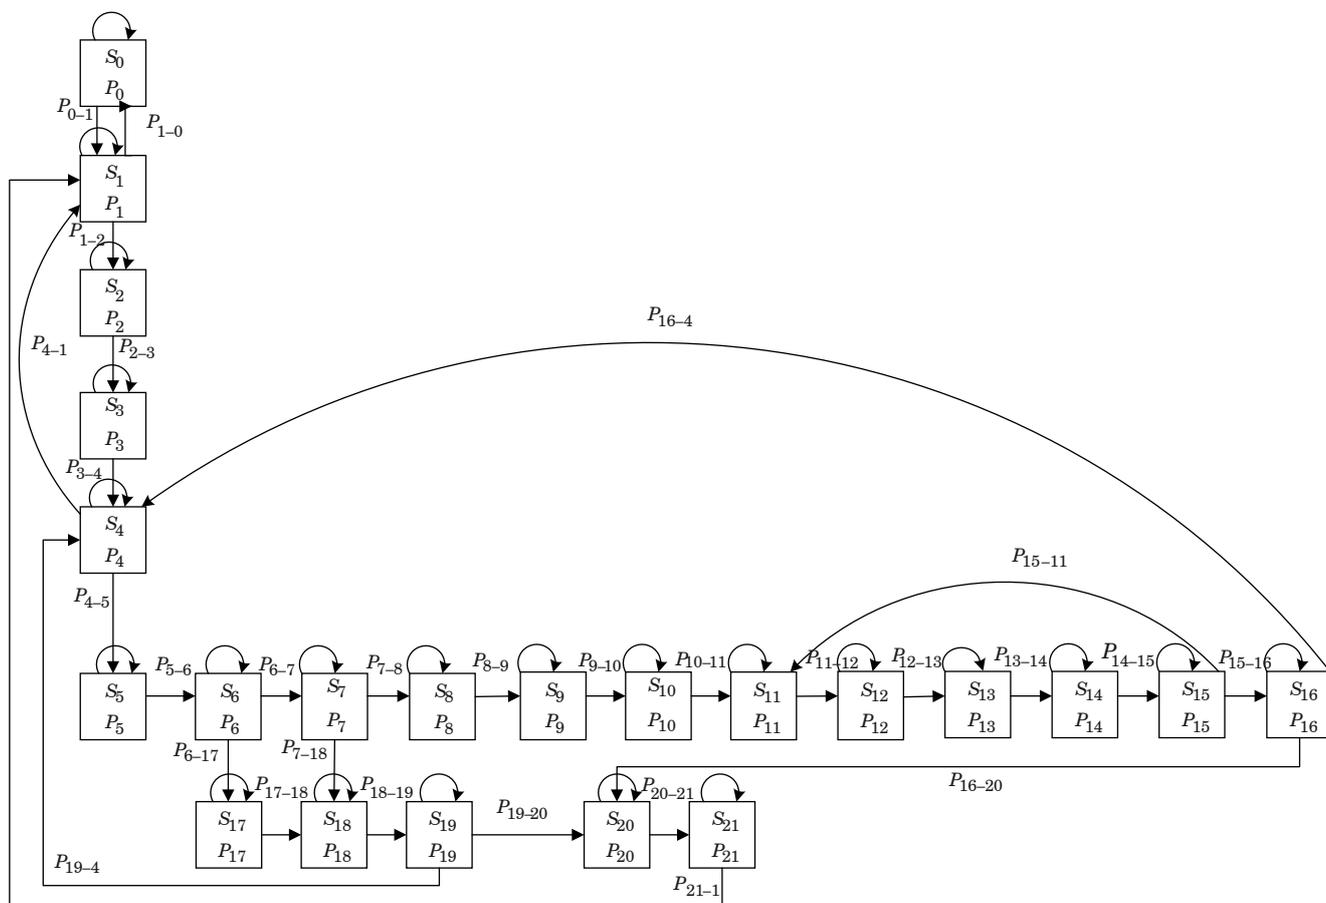
Если же аномалия сетевого трафика не является причиной несоответствия, то проводится сравнение параметров настройки ТКО и СЗИ с правилами, установленными политикой безопасности. Далее установленные нарушения правил настройки ТКО и СЗИ устраняются в соответствии с выработанными предложениями [16, 17], после чего СПД продолжает свое функционирование в штатном режиме.

Цикл управления СИБ заканчивается тем, что проверяется уровень защищенности СПД после устранения несоответствий политике безопасности. Если уровень защищенности ниже требуемого, то необходимо повторно провести выявление несоответствий с последующим вы-

полнением вышеописанных процессов, иначе формируется отчет о выявленном инциденте ИБ.

Для более детального исследования процесса функционирования СИБ СПД объекта КИИ при реализации МЭА данный процесс формализован в виде математической модели [18–21]. Модель представляет собой граф состояний СИБ, при этом переход одного стационарного состояния в другое происходит в произвольный момент времени и зависит только от параметров системы в данный конкретный момент времени [22, 23]. В результате строится граф состояний процесса функционирования СИБ СПД объекта КИИ при МЭА (рис. 3, табл. 1).

Показатель защищенности СПД зависит от сложившейся обстановки в информационном пространстве. Рассмотрим ситуацию, при которой осуществляется МЭА. В данном случае показатель защищенности определяется как вероятность нахождения СИБ в состоянии (S_{16}) устранения уязвимости и восстановления штатного режима функционирования СПД после парирования МЭА (P_3) [24, 25]. Вероятность P_3 принята за вероятность защищенности, если считать, что



■ **Рис. 3.** Граф состояний процесса функционирования СИБ СПД при МЭА
 ■ **Fig. 3.** Graph of the states of the process of functioning of the DTN ISS under MSA

■ **Таблица 1.** Процессы функционирования СИБ СПД при МЭА
 ■ **Table 1.** Processes of functioning of the DTN ISS under the MSA

Событие	Описание
S_0	Исходное состояние СИБ СПД
S_1	Формирование модели функционально-логической архитектуры СПД
S_2	Формирование модели протоколов СПД
S_3	Формирование модели цифрового потока СПД
S_4	Выявление несоответствий параметров политике безопасности информации СПД
S_5	Изменение штатного режима функционирования СПД на время устранения причины
S_6	Определение причины несоответствия политике безопасности
S_7	Анализ аномалии
S_8	Определение геолокации нарушителя
S_9	Многокритериальная классификация МЭА с использованием метода машинного обучения
S_{10}	Определение причин возникновения МЭА
S_{11}	Прогнозирование направления и цели воздействия на элементы СПД
S_{12}	Построение графа атаки
S_{13}	Выявление уязвимостей элементов СПД на основе анализа графа атаки
S_{14}	Выработка предложений по парированию МЭА на основе оценки рисков
S_{15}	Принятие мер по парированию МЭА
S_{16}	Устранение уязвимости и восстановление штатного режима функционирования СПД
S_{17}	Анализ причин несоответствия
S_{18}	Выработка предложений по изменению параметров ТКО и СЗИ
S_{19}	Изменение параметров ТКО и СЗИ и сохранение в журнал событий
S_{20}	Формирование СИБ отчета о МЭА
S_{21}	Добавление статистических данных

после парирования МЭА сразу же приступает к формированию отчета. Таким образом, вероятность защищенного состояния СПД примет вид

$$P_3 = \frac{\lambda_0}{\mu_0} \left(\frac{\beta_1 \beta_2 \beta_3 \lambda_{1-2} (\beta_2 + \varphi) (\beta_3 + \psi) ((\beta_1 + \eta)(\rho + \omega) - \beta_1 \omega) + \beta_1^2 \beta_2 \beta_3 \omega \lambda_{1-2} (\varphi(\beta_3 + \psi) + \beta_2 \psi)}{((\beta_1 + \eta)(\beta_2 + \varphi)(\beta_3 + \psi)(\rho + \omega) - \beta_1 \beta_2 \beta_3 \omega) ((\beta_1 + \eta)(\beta_2 + \varphi)(\beta_3 + \psi)(\rho + \omega) - \beta_1 \omega)} \right) P_0.$$

Здесь

$$P_0 = \frac{1}{1 + \frac{\lambda_0}{\mu_0} + \frac{\lambda_0 \lambda_{1-2}}{\mu_0 \lambda_{2-3}} + \frac{\lambda_0 \lambda_{1-2}}{\mu_0 \lambda_{3-4}} + C + D \left(\begin{aligned} &1 + \frac{\beta_1}{\lambda_{5-6}} + \frac{\beta_1}{\beta_2 + \varphi} + \frac{\beta_1 \beta_2}{(\beta_2 + \varphi)(\beta_3 + \psi)} + \\ &\left(\frac{1}{\lambda_{8-9}} + \frac{1}{\lambda_{9-10}} + \frac{1}{\lambda_{10-11}} + \right. \\ &\left. + \left(\frac{1}{\lambda_{11-12}} + \frac{1}{\lambda_{12-13}} + \frac{1}{\lambda_{13-14}} + \frac{1}{\lambda_{14-15}} \right) \left(1 + \frac{\alpha}{\varepsilon} \right) + \frac{1}{\varepsilon} \right) + \\ &\left. + \frac{\beta_1 \varphi}{\lambda_{17-18} (\beta_2 + \varphi)} + \frac{\beta_1 (\beta_3 + \psi) \varphi + \beta_1 \beta_2 \psi}{\lambda_{18-19} (\beta_2 + \varphi) (\beta_3 + \psi)} \right) + A + B + (A + B) \left(\frac{\rho}{\lambda_{20-21}} + \frac{\rho}{\mu_0} \right)},$$

где

$$A = \frac{\lambda_0}{\mu_0} \frac{\beta_1 \beta_2 \beta_3 \lambda_{1-2} \times ((\beta_1 + \eta)(\beta_2 + \varphi)(\beta_3 + \psi)(\rho + \omega) - \beta_1 \omega) + \beta_1^2 \beta_2 \beta_3 \omega \lambda_{1-2} (\varphi(\beta_3 + \psi) + \beta_2 \psi)}{((\beta_1 + \eta)(\beta_2 + \varphi)(\beta_3 + \psi)(\rho + \omega) - \beta_1 \beta_2 \beta_3 \omega) \times ((\beta_1 + \eta)(\beta_2 + \varphi)(\beta_3 + \psi)(\rho + \omega) - \beta_1 \omega)}$$

$$B = \frac{\lambda_0}{\mu_0} \frac{\lambda_{1-2} \beta_1 (\varphi(\beta_3 + \psi) + \beta_2 \psi)}{(\beta_1 + \eta)(\beta_2 + \varphi)(\beta_3 + \psi)(\rho + \omega) - \beta_1 \omega}$$

$$C = \frac{\lambda_0}{\mu_0} \frac{\lambda_{1-2}}{\beta_1 + \eta} + \frac{\omega}{\beta_1 + \eta} (A + B);$$

$$D = \frac{\beta_1 \beta_2 \beta_3}{(\beta_2 + \varphi)(\beta_3 + \psi)}$$

Верификация с помощью программного обеспечения

Для оптимизации расчета процессов функционирования СИБ СПД при МЭА разработано программное обеспечение (ПО) на языке Python (рис. 4), позволяющее в наглядной форме получить вывод необходимых зависимостей.

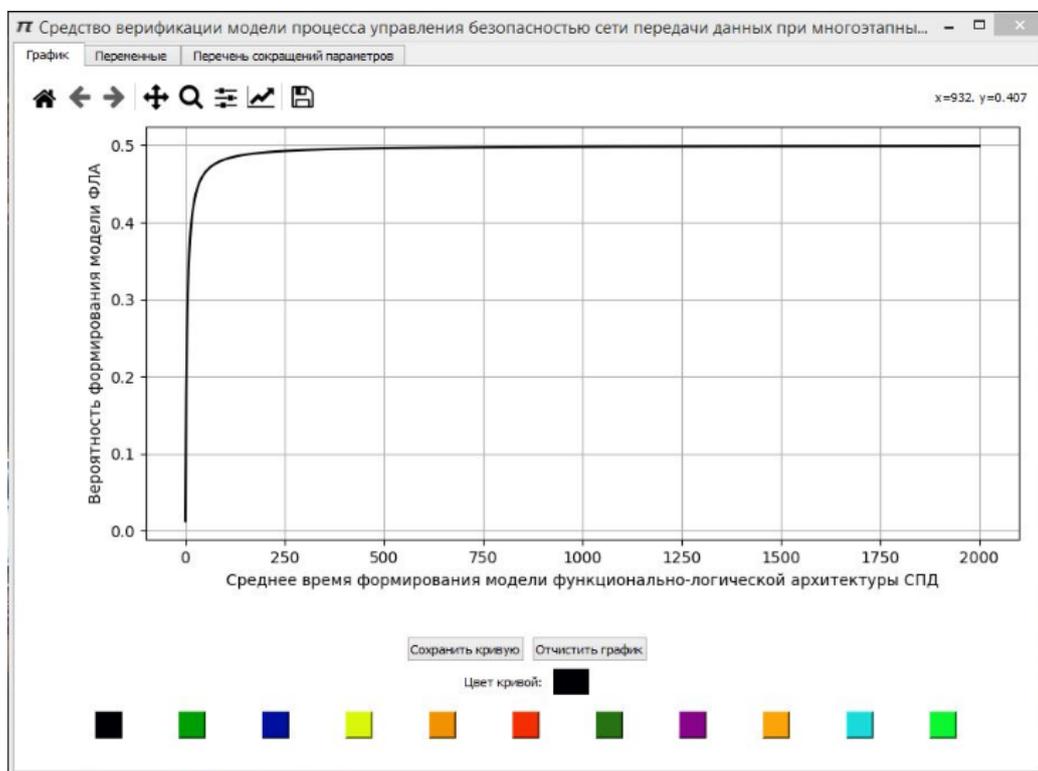
В разработанное ПО [26] были введены исходные данные из табл. 2 [27–30], являющиеся экспертными оценками. Программный продукт в автоматическом режиме построил зависимости вероятности защищенности СПД от различного времени определения причин несоответствия политике безопасности (от 0,005 до 0,05 мин) (рис. 5, а) и различного времени принятия мер по парированию МЭА (от 0,09 до 0,27 мин) (рис. 5, б).

Из рис. 5 следует, что увеличение времени определения геолокации нарушителя СИБ СПД при МЭА понижает защищенность P_3 ниже требуемого уровня 0,9. В связи с этим возможно определить требования к времени определения геолокации нарушителя в различных условиях функционирования СИБ СПД, например:

1) время определения геолокации нарушителя $\leq 0,495$ мин при времени определения причины несоответствия политике безопасности за 0,05 мин;

2) время определения геолокации нарушителя $\leq 0,67$ мин при времени принятия мер по парированию МЭА за 0,009 мин.

При количественных оценках для подтверждения новых предложений полученные результаты аналитического моделирования показали, что предложенный подход в сравнении с [31, 32] обеспечивает требуемый уровень достоверности



■ **Рис. 4.** Интерфейс ПО для оперативного расчета вероятностей защищенности СПД
 ■ **Fig. 4.** The software interface for quick calculation of DTN security probabilities

- **Таблица 2.** Исходные данные для расчета оценки вероятности защищенности СПД при МЭА
- **Table 2.** Input data for calculating the probability of protection of the DTN during the MSA

Событие	Описание	Значение, мин
S_0	Исходное состояние СИБ СПД	0,0055
S_1	Формирование модели функционально-логической архитектуры СПД	0,003
S_2	Формирование модели цифрового потока СПД	0,003
S_3	Формирование модели протоколов СПД	0,003
S_4	Выявление несоответствий параметров политике безопасности СПД	0,1
		0,001
S_5	Изменение штатного режима функционирования СПД на время устранения причины	0,052
S_6	Определение причины несоответствия политике безопасности	1
		0,005
		0,025
S_7	Анализ аномалии	0,005
		3
S_8	Определение геолокации нарушителя	Переменная
S_9	Многокритериальная классификация МЭА с использованием метода машинного обучения	0,001
S_{10}	Определение причин возникновения МЭА	0,008
S_{11}	Прогнозирование направления и цели воздействия на элементы СПД	0,055
S_{12}	Построение графа атаки	0,051
S_{13}	Выявление уязвимостей элементов СПД на основе анализа графа атаки	0,051
S_{14}	Выработка предложений по парированию МЭА на основе оценки рисков	0,005
S_{15}	Принятие мер по парированию МЭА	0,09
		0,18
		0,27
S_{16}	Устранение уязвимости и восстановление штатного режима функционирования	0,4
		8
S_{17}	Анализ причин несоответствия	8
		8
S_{18}	Выработка предложений по изменению параметров ТКО и СЗИ	0,5
S_{19}	Изменение параметров ТКО и СЗИ и сохранение в журнал событий	0,005
		8
S_{20}	Изменение параметров ТКО и СЗИ и сохранение в журнал событий	8
		8
S_{21}	Формирование СИБ отчета о МЭА	0,5
S_{22}	Добавление статистических данных	0,005

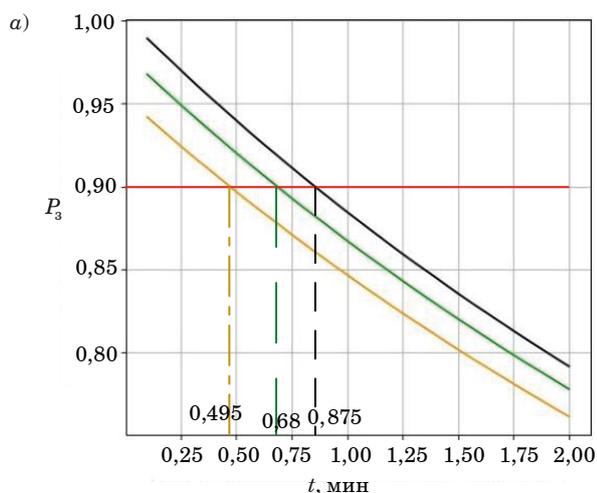
принимаемых решений. Применение методики позволяет поднять значение вероятности защищенности СПД при МЭА выше 0,9.

Определено, что при использовании результатов моделирования можно реализовать способы повышения защищенности СПД от МЭА. Разработанный алгоритм может быть использован в уже существующих системах ИБ, поскольку он представляет собой инструмент выявления и прогнозирования МЭА. Проведены экспери-

ментальная и теоретическая оценка эффективности предложений, а также сравнение с существующими методиками.

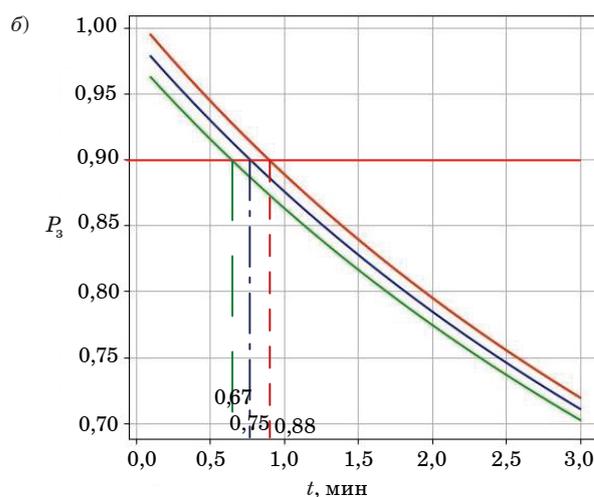
Заключение

Методика включает превентивный анализ динамики действий нарушителя, обнаружение несоответствий политике безопасности, опре-



При времени определения причины несоответствия политике безопасности, мин:

- — — 0,005
- — — 0,025
- — — 0,05
- — — требования защищенности



При времени принятия мер по парированию МЭА, мин:

- — — 0,009
- — — 0,018
- — — 0,27
- — — требования защищенности

■ **Рис. 5.** Зависимость вероятности защищенности от времени определения геолокации нарушителя при различном времени определения причин несоответствия политике безопасности (а) и принятия мер по парированию МЭА (б)
 ■ **Fig. 5.** The dependence of the probability of security on the time of determining the geolocation of the intruder at various times of taking measures of non-compliance with the information security policy (а) and parry the MSA (б)

деление параметров аномалий сетевого трафика, классификацию видов атак и определение геолокации нарушителя. Представлен алгоритм управления ИБ СПД КИИ при стохастической неопределенности.

Процесс обеспечения защищенности СПД был формализован с помощью математического аппарата теории марковских процессов с дискретными состояниями и непрерывным временем, что позволило получить зависимости вероятности защищенности СПД от времени различных подпроцессов СИБ в наглядном графическом виде. Результаты моделирования показали, что предложенная методика обеспечивает повыше-

ние вероятности защищенности СПД в течение заданного времени и как следствие дает условия для своевременного предоставления СПД качественных услуг конечным пользователям. Также результаты демонстрируют обоснованность временных параметров СИБ, максимизирующих время защищенности СПД при МЭА.

Дальнейшие исследования будут направлены на автоматизацию предлагаемой методики и ее синтез с другими известными способами защиты СПД, а также на интеллектуализацию процессов раннего обнаружения и анализа действий нарушителя в сети.

Литература

1. **Зеличенко И. Ю., Котенко И. В.** Выявление многошаговых атак при помощи рекуррентных нейронных сетей с применением слоев LSTM. *Региональная информатика (РИ-2022): материалы юбилейной XVIII Санкт-Петербургской международной конф., Санкт-Петербург, 26–28 октября 2022 г.* СПб., 2022, с. 157–158.
2. **Зеличенко И. Ю., Котенко И. В.** Методы выявления многошаговых атак на компьютерные сети с помощью машинного обучения. *Региональная информатика (РИ-2022): материалы юбилейной XVIII Санкт-Петербургской международной конф., Санкт-Петербург, 26–28 октября 2022 г.* СПб., 2022, с. 159–160.

3. **Котенко Д. И., Котенко И. В., Саенко И. Б.** Методы и средства моделирования атак в больших компьютерных сетях: состояние проблемы. *Труды СПИИРАН*, 2012, № 3(22), с. 5–30.
4. **Климов С. М.** *Методы и модели противодействия компьютерным атакам.* Люберцы, КАТАЛИТ, 2008. 316 с.
5. **Липатников В. А., Шевченко А. А., Косолапов В. С., Сокол Д. С.** Метод обеспечения информационной безопасности сети VoIP-телефонии с прогнозом стратегии вторжений нарушителя. *Информационно-управляющие системы*, 2022, № 1, с. 54–67. doi:10.31799/1684-8853-2022-1-54-67
6. **Visoottiviset V., Sakarin P., Thongwilai J., Chobanjong T.** Signature-based and behavior-based

- attack detection with machine learning for home IoT devices. *2020 IEEE Region 10 Conference (TENCON)*, Osaka, Japan, 2020, 16–19 November. IEEE, 2020, pp. 829–834. doi:10.1109/TENCON50793.2020.9293811
7. Зегжда Д. П., Васильев Ю. С., Полтавцева М. А., Кефели И. Ф., Боровков А. И. Кибербезопасность прогрессивных производственных технологий в эпоху цифровой трансформации. *Вопросы кибербезопасности*, 2018, № 2 (26), с. 2–15. doi:10.21681/2311-3456-2018-2-2-15, EDN: UYNEXS
 8. Williams J. *Identification of IP Address using Fraudulent Geolocation Data*. Imperial College London, 15 June 2020. [https://www.imperial.ac.uk/media/imperial-college/faculty-of-engineering/computing/public/1920-ug-projects/Williams,-James-\(jw1317\).pdf](https://www.imperial.ac.uk/media/imperial-college/faculty-of-engineering/computing/public/1920-ug-projects/Williams,-James-(jw1317).pdf) (дата обращения: 28.01.2023).
 9. Wang Z., Li H., Li Q., Li W., Zhu H., Sun L. Towards IP geolocation with intermediate routers based on topology discovery. *Cybersecurity*, 2019, vol. 2, iss. 1. <https://doi.org/10.1186/s42400-019-0030-2>
 10. Пат. RU 2100839 С1 РФ, МПК G06F 17/30. *Устройство поиска информации*, В. А. Липатников (РФ), А. М. Плотников (РФ), В. В. Якимовец (РФ). № 95108104/09; заявл. 18.05.1995; опубл. 27.12.1997, 11 с.
 11. Пат. RU 2199148 С1 РФ, МПК G06F 17/30. *Устройство поиска информации*, В. А. Липатников (РФ), В. В. Якимовец (РФ), Д. Л. Хлыбов (РФ). № 2001120395/09; заявл. 20.07.2001; опубл. 20.02.2003, 18 с.
 12. Липатников В. А., Мелехов К. В., Задбоев В. А. Способ определения локации злоумышленника в сети передачи данных сетевой инфраструктуры. *Транспорт России: проблемы и перспективы: материалы Междунар. науч.-практ. конф.*, Санкт-Петербург, 9–10 ноября 2022 г. СПб., 2022, с. 215–220. EDN: KDDQDW
 13. Taylor J., Devlin J., Curran K. Bringing location to IP addresses with IP geolocation. *The Journal of Emerging Technologies in Web Intelligence*, 2012, vol. 4, no. 3, pp. 273–277.
 14. Коршунов Г. И., Липатников В. А., Шевченко А. А., Малышев Б. Ю. Метод адаптивного управления защитой информационно-вычислительных сетей на основе анализа динамики действий нарушителя. *Информационно-управляющие системы*, 2018, № 4, с. 61–72. doi:10.31799/1684-8853-2018-4-61-72
 15. Ageev S., Kotenko I., Saenko I., Korchak Y. Abnormal traffic detection in networks of the Internet of things based on fuzzy logical inference. *Proc. of the 18th Intern. Conf. on Soft Computing and Measurements, SCM 2015*, Saint-Petersburg, 2015, 19–21 May. Saint-Petersburg, 2015, pp. 5–8. doi:10.1109/SCM.2015.7190394, EDN: WRWUMV
 16. Липатников В. А., Шевченко А. А., Яцкин А. Д., Семенова Е. Г. Управление информационной безопасностью организации интегрированной структуры на основе выделенного сервера с контейнерной виртуализацией. *Информационно-управляющие системы*, 2017, № 4, с. 67–76. doi:10.15217/issn1684-8853.2017.4.67
 17. Brezigar-Masten A., Masten I. CART-based selection of bankruptcy predictors for the logit model. *Expert Systems with Applications*, 2012, vol. 39, no. 11, pp. 10153–10159.
 18. Ju X., Chen V. C. P., Rosenberger J. M., Liu F. Fast knot optimization for multivariate adaptive regression splines using hill climbing methods. *Expert Systems with Applications*, 2021, no. 171, p. 114565. doi:10.1016/j.eswa.2021.114565
 19. Clincy V., Shahriar H. Web application firewall: Network security models and configuration. *2018 IEEE 42nd Annual Computer Software and Applications Conf. (COMPSAC)*, Tokyo, Japan, 2018, 23–27 July. IEEE, 2018, pp. 835–836. doi:10.1109/COMPSAC.2018.00144
 20. Шевченко А. А. Математическая модель информационного противоборства двух систем в информационно-телекоммуникационном пространстве. *Инновационная деятельность в Вооруженных Силах Российской Федерации: труды всероссийской научно-практической конференции*, Санкт-Петербург, 14–15 октября 2020 г. СПб., 2020, с. 237–241. EDN: WZBIFU
 21. Ju X., Rosenberger J. M., Chen V. C. P., Liu F. Global optimization on non-convex two-way interaction truncated linear multivariate adaptive regression splines using mixed integer quadratic programming. *Information Sciences*, 2022, no. 597, pp. 38–52.
 22. Ju X., Liu F., Wang Li., Lee W.-J. Wind farm layout optimization based on support vector regression guided genetic algorithm with consideration of participation among landowners. *Energy Conversion and Management*, 2019, no. 196, pp. 1267–1281. doi:10.1016/j.enconman.2019.06.082
 23. Шевченко А. А. Модель процесса защиты информационно-телекоммуникационной сети от несанкционированного воздействия. *Инновационная деятельность в Вооруженных Силах Российской Федерации: труды всероссийской научно-практической конференции*, Санкт-Петербург, 10–11 октября 2019 г. СПб., 2019, с. 166–173. EDN: NBCDWB
 24. Смирнова Е. В., Абачараева Э. Р. Современные угрозы вирусных атак на компьютерные сети и критерии их оценивания. *Технологии инженерных и информационных систем*, 2020, № 3, с. 3–12. EDN: JQNNAV
 25. Pratap U., Canudas-de-Wit C., Garin F. Average state estimation in presence of outliers. *2020 59th IEEE Conf. on Decision and Control (CDC)*, Jeju, Korea (South), 2020, 14–18 December. IEEE, 2020, pp. 6058–6063. doi:10.1109/CDC42340.2020.9303809
 26. Amma N. G. B., Selvakumar S., Velusamy R. L. A statistical approach for detection of denial of service attacks in computer networks. *IEEE Transactions on*

- Network and Service Management*, 2020, vol. 17, no. 4, pp. 2511–2522. doi:10.1109/TNSM.2020.3022799
27. Куликов А. Л., Бездушный Д. И., Шарьгин М. В., Осокин В. Ю. Анализ применения метода опорных векторов в многомерной релейной защите. *Известия Российской академии наук. Энергетика*, 2020, № 2, с. 123–132. doi:10.31857/S0002331020020065, EDN: PVUKFW
28. Свидетельство о государственной регистрации программы для ЭВМ № 2023664605 Российская Федерация. Средство верификации модели процесса управления безопасностью сети передачи данных при многоэтапных атаках: № 2023663624: заявлено 27.06.2023; опубликовано 05.07.2023 Бюл. № 7 / Мелехов К. В., Липатников В. А., Петренко М. И., Шевченко А. А., Парфириков В. А., Мелихов И. А., Мезенин М. Е.; правообладатель Мелехов К. В. — Зарегистрировано в Реестре программ для ЭВМ.
29. Липатников В. А., Тихонов В. А. Распознавание вторжений нарушителя при управлении кибер-безопасностью инфраструктуры интегрированной организации на основе нейро-нечетких сетей и когнитивного моделирования. *Актуальные проблемы инфотелекоммуникаций в науке и образовании (АПИНО 2019): сб. науч. ст. VIII Междунар. науч.-техн. и науч.-метод. конф.*, Санкт-Петербург, 27–28 февраля 2019 г. СПб., 2019, т. 4, с. 659–664. EDN: AWSFFH
30. Karataş G., Akbulut A. Survey on access control mechanisms in cloud computing. *Journal of Cyber Security and Mobility*, 2018, vol. 7, no. 3, pp. 1–36. doi:10.13052/2245-1439.731
31. Lopez J., Rubio J. Access control for cyber-physical systems interconnected to the cloud. *Comput. Netw.*, 2018, vol. 134, no. C, pp. 46–54.
32. Yin A., Zhang C. BOFE: Anomaly detection in linear time based on feature estimation. *2018 IEEE Intern. Conf. on Data Mining Workshops (ICDMW)*, Singapore, 2018, 17–20 November. IEEE, 2018, pp. 1128–1133. doi:10.1109/ICDMW.2018.00162

UDC 004.056.53

doi:10.31799/1684-8853-2024-1-44-55

EDN: MVWIFR

Methodology for improving the security of the data transmission network of critical information infrastructure objects under multi-stage attacks

V. A. Lipatnikov^a, Dr. Sc., Tech., Professor, Senior Researcher, orcid.org/0000-0002-3736-4743, lipatnikovanl@mail.ru

A. A. Shevchenko^a, PhD, Tech, Senior Researcher, orcid.org/0000-0001-9113-1089

K. V. Melekhov^a, Post-Graduate Student, orcid.org/0009-0007-3474-412X

D. F. Tkachev^a, PhD, Tech., Head of Division, orcid.org/0009-0004-2256-9270

^aS. M. Budenny Military Academy of Communication, 3, Tikhoretskii Pr., 190064, Saint-Petersburg, Russian Federation

Introduction: The fast-paced development of information technologies leads to the emergence of new threats and vulnerabilities in information systems across various societal areas, the exploitation of which increases the probability of a successful attack by an intruder. Consequently, it is essential to research techniques for improving the security of data networks in the face of multi-stage attacks.

Purpose: To improve the security of the data network by proactively managing security against multi-stage attacks. **Result:** We develop a methodology for improving the security of data transmission networks under multi-stage attacks based on proactive security management. The methodology includes preventive analysis of intruder dynamics, detection of security policy inconsistencies, determination of network traffic anomaly parameters, classification of attack types and determination of intruder geolocation. The process of ensuring the security of the data network has been formalized using the mathematical apparatus of the theory of Markov processes with discrete states and continuous time, which makes it possible to obtain the dependencies of the probability of data network security on the time of various sub-processes of the information security system in a clear graphical form. The results of modeling show that the proposed methodology provides an increase in the probability of data transmission network security within a given time and as a consequence provides conditions for timely provision of data transmission network quality services to end users. **Practical relevance:** The methodology is a mathematical basis for the information security system, taking into account the parameters of the impact and protection processes to take effective measures to parry multi-stage attacks using machine learning. The study's findings can be applicable in developing or troubleshooting information security systems for data transmission networks of critical information infrastructure objects.

Keywords — proactive management, data network, multi-stage attack, critical information infrastructure object, machine learning method, geolocation, information security, anomalies, network traffic.

For citation: Lipatnikov V. A., Shevchenko A. A., Melekhov K. V., Tkachev D. F. Methodology for improving the security of the data transmission network of critical information infrastructure objects under multi-stage attacks. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 44–55 (In Russian). doi:10.31799/1684-8853-2024-1-44-55, EDN: MVWIFR

References

- Zelichenok I. Yu., Kotenko I. V. Detection of multi-step attacks using recurrent neural networks with LSTM layers. *Materialy yubilejnoj XVIII Sankt-Peterburgskoj Mezhdunarodnoj konferencii "Regional'naya informatika (RI-2022)"* [Proc. of the Anniversary XVIII St. Petersburg Intern. Conf. "Regional informatics (RI-2022)"]. Saint-Petersburg, 2022, pp. 157–158 (In Russian).
- Zelichenok I. Yu., Kotenko I. V. Methods for detecting multi-step attacks on computer networks by using machine learning. *Materialy yubilejnoj XVIII Sankt-Peterburgskoj Mezhdunarodnoj konferencii "Regional'naya informatika (RI-2022)"* [Proc. of the Anniversary XVIII St. Petersburg Intern. Conf. "Regional informatics (RI-2022)"]. Saint-Petersburg, 2022, pp. 159–160 (In Russian).

3. Kotenko D. I., Kotenko I. V., Saenko I. B. Methods and tools for attack modeling in large computer networks: State of the problem. *SPIIRAS Proceedings*, 2012, iss. 3(22), pp. 5–30 (In Russian).
4. Klimov S. M. *Metody i modeli protivodejstviya komp'yuternym atakam* [Methods and models for countering computer attacks]. Lyubercy, KATALIT Publ., 2008. 316 p. (In Russian).
5. Lipatnikov V. A., Shevchenko A. A., Kosolapov V. S., Sokol D. S. Method for ensuring information security of a VoIP telephony network with a forecast of an intruder's intrusion strategy. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2022, no. 1, pp. 54–67 (In Russian). doi:10.31799/1684-8853-2022-1-54-67
6. Visoottiviset V., Sakarin P., Thongwilai J., Choobanjong T. Signature-based and behavior-based attack detection with machine learning for home IoT devices. *2020 IEEE Region 10 Conf. (TENCÓN)*, 2020, pp. 829–834. doi:10.1109/TENCON50793.2020.9293811
7. Zegzhda D. P., Vasilev U. S., Poltavtseva M. A., Kefelev I. F., Borovkov A. I. Advanced production technologies security in the era of digital transformation. *Voprosy kiberbezopasnosti*, 2018, no. 2 (26), pp. 2–15 (In Russian). doi:10.21681/2311-3456-2018-2-2-15, EDN: UYNEXS
8. Williams J. *Identification of IP Address using Fraudulent Geolocation Data*. Imperial College London, 15 June 2020. Available at: [https://www.imperial.ac.uk/media/imperial-college/faculty-of-engineering/computing/public/1920-ug-projects/Williams,-James-\(jw1317\).pdf](https://www.imperial.ac.uk/media/imperial-college/faculty-of-engineering/computing/public/1920-ug-projects/Williams,-James-(jw1317).pdf) (accessed 28 January 2023).
9. Wang Z., Li H., Li Q., Li W., Zhu H., Sun L. Towards IP geolocation with intermediate routers based on topology discovery. *Cybersecurity*, 2019, vol. 2, iss. 1. <https://doi.org/10.1186/s42400-019-0030-2>
10. Lipatnikov V. A., et al. *Ustrojstvo poiska informacii* [Information retrieval device]. Patent RF, no. RU 2100839 C1, 1997.
11. Lipatnikov V. A., et al. *Ustrojstvo poiska informacii* [Information retrieval device]. Patent RF, no. RU 2199148 C1, 2003.
12. Lipatnikov V. A., Melekhov K. V., Zadboev V. A. A method of detection of an intruder's location in the data network of the network infrastructure. *Materialy Mezhdunarodnoj nauchno-prakticheskoy konferencii "Transport Rossii: problemy i perspektivy"* [Proc. of the Intern. Scientific and Practical Conf. "Transport of Russia: problems and prospects"]. Saint-Petersburg, 2022, pp. 215–220 (In Russian). EDN: KDDQDW
13. Taylor J., Devlin J., Curran K. Bringing location to IP addresses with IP geolocation. *The Journal of Emerging Technologies in Web Intelligence*, 2012, vol. 4, no. 3, pp. 273–277.
14. Korshunov G. I., Lipatnikov V. A., Shevchenko A. A., Malyshov B. Y. Adaptive management of information network protection with analysis of intruder's actions. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2018, no. 4, pp. 61–72 (In Russian). doi:10.31799/1684-8853-2018-4-61-72
15. Ageev S., Kopchak Y., Kotenko I., Saenko I. Abnormal traffic detection in networks of the Internet of things based on fuzzy logical inference. *Proc. of the IEEE 18th Intern. Conf. on Soft Computing and Measurements, SCM 2015*. Saint-Petersburg, 2015, pp. 5–8. doi:10.1109/SCM.2015.7190394, EDN: WRWUMV
16. Lipatnikov V. A., Shevchenko A. A., Yatskin A. D., Semenova E. G. Information security management of integrated structure organization based on a dedicated server with container virtualization. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2017, no. 4, pp. 67–76 (In Russian). doi:10.15217/issn1684-8853.2017.4.67
17. Brezigar-Masten A., Masten I. CART-based selection of bankruptcy predictors for the logit model. *Expert Systems with Applications*, 2012, vol. 39, no. 11, pp. 10153–10159.
18. Ju X., Chen V. C. P., Rosenberger J. M., Liu F. Fast knot optimization for multivariate adaptive regression splines using hill climbing methods. *Expert Systems with Applications*, 2021, no. 171, p. 114565. doi:10.1016/j.eswa.2021.114565
19. Clincy V., Shahriar H. Web application firewall: Network security models and configuration. *2018 IEEE 42nd Annual Computer Software and Applications Conf. (COMPSAC)*. IEEE, 2018, pp. 835–836.
20. Shevchenko A. A. Mathematical model of the information confrontation between two systems in the field of info-telecommunication. *Innovacionnaya deyatel'nost' v Vooruzhennykh Silakh Rossijskoj Federacii: Trudy vsearmejskoj nauchno-prakticheskoy konferencii* [Proc. of the All-Army Scientific and Practical Conf. "Innovative activities in the Armed Forces of the Russian Federation"]. Saint-Petersburg, 2020, pp. 237–241 (In Russian). EDN: WZBIFU
21. Ju X., Rosenberger J. M., Chen V. C. P., Liu F. Global optimization on non-convex two-way interaction truncated linear multivariate adaptive regression splines using mixed integer quadratic programming. *Information Sciences*, 2022, no. 597, pp. 38–52.
22. Ju X., Liu F., Wang Li., Lee W.-J. Wind farm layout optimization based on support vector regression guided genetic algorithm with consideration of participation among landowners. *Energy Conversion and Management*, 2019, no. 196, pp. 1267–1281. doi:10.1016/j.enconman.2019.06.082
23. Shevchenko A. A. Model of the information protection process of info-telecommunication network from unauthorized influence. *Innovacionnaya deyatel'nost' v Vooruzhennykh Silakh Rossijskoj Federacii: Trudy vsearmejskoj nauchno-prakticheskoy konferencii* [Proc. of the All-Army Scientific and Practical Conf. "Innovative activities in the Armed Forces of the Russian Federation"]. Saint-Petersburg, 2019, pp. 166–173 (In Russian). EDN: NBCDWB
24. Smirnova E. V., Abacharaeva E. R. Modern threats of computer networks virus attacks and their evaluation criteria. *Technologies of Engineering and Information Systems*, 2020, no. 3, pp. 3–12 (In Russian). EDN: JQNNAV
25. Pratap U., Canudas-de-Wit C., Garin F. Average state estimation in presence of outliers. *2020 59th IEEE Conf. on Decision and Control (CDC)*. IEEE, 2020, pp. 6058–6063. doi:10.1109/CDC42340.2020.9303809
26. Amma N. G. B., Selvakumar S., Velusamy R. L. A statistical approach for detection of denial of service attacks in computer networks. *IEEE Transactions on Network and Service Management*, 2020, vol. 17, no. 4, pp. 2511–2522. doi:10.1109/TNSM.2020.3022799
27. Kulikov A. L., Bezdushny D. I., Sharygin M. V., Osokin V. Yu. The support vector machine application analysis in multidimensional relay protection. *Proceedings of the Russian Academy of Sciences. Power Engineering*, 2020, no. 2, pp. 123–132 (In Russian). doi:10.31857/S0002331020020065, EDN: PVUKFW
28. Melekhov K. V., et al. *Sredstvo verifikacii modeli processa upravleniya bezopasnost'yu seti peredachi dannykh pri mnogetapnykh atakah* [A tool for verifying the data network security management process model during multi-stage attacks]. Certificate Russian Federation No. 2023664605, 2023.
29. Lipatnikov V. A., Tikhonov V. A. Recognition of offenders actions in the management of cyber security of the integrated organization infrastructure on the basis of neuro-fuzzy networks and cognitive modeling. *Sbornik nauchnykh statej VIII Mezhdunarodnoj nauchno-tekhnicheskoy i nauchno-metodicheskoy konferencii "Aktual'nye problemy infotele-kommunikacij v nauke i obrazovanii (APINO 2019)* [Proc. of the VIII Intern. Scientific-Technical and Scientific-Methodological Conf. "Current problems of information and telecommunications in science and education"]. Saint-Petersburg, 2019, vol. 4, pp. 659–664 (In Russian). EDN: AWSFFH
30. Karataş G., Akbulut A. Survey on access control mechanisms in cloud computing. *Journal of Cyber Security and Mobility*, 2018, vol. 7, no. 3, pp. 1–36. doi:10.13052/2245-1439.731
31. Lopez J., Rubio J. Access control for cyber-physical systems interconnected to the cloud. *Comput. Netw.*, 2018, vol. 134, no. C, pp. 46–54.
32. Yin A., Zhang C. BOFE: Anomaly detection in linear time based on feature estimation. *2018 IEEE Intern. Conf. on Data Mining Workshops (ICDMW)*. IEEE, 2018, pp. 1128–1133. doi:10.1109/ICDMW.2018.00162



Соотношения для расчета диаграммы направленности МИМО РЛС при различающихся антеннах приемных и передающих элементов, формирующих ее

М. А. Степанов^а, доктор техн. наук, доцент, orcid.org/0000-0001-6095-1172, m.stepanov@corp.nstu.ru

В. С. Соколов^а, аспирант, orcid.org/0009-0001-2210-3970

^аНовосибирский государственный технический университет, К. Маркса пр., 20, Новосибирск, 630073, РФ

Введение: синтез антенных решеток МИМО отличается от синтеза классических антенных решеток тем, что диаграмма направленности первых формируется виртуальной апертурой, которая образуется путем свертки координат физических приемных и передающих элементов, что приводит к формированию большого числа виртуальных элементов. **Цель:** получить соотношения для вычисления диаграмм направленности антенных решеток МИМО радиолокационной станции при различающихся антеннах приемных и передающих элементов, формирующих ее. **Результаты:** получено выражение для расчета множителя направленности антенной решетки МИМО радиолокационной станции, позволяющее уменьшить количество математических операций в сравнении с расчетом по расположению элементов виртуальной апертуры. На его основе определено выражение, позволяющее учесть влияние диаграмм направленности антенн приемных и передающих элементов МИМО антенной решетки на ее направленные свойства. Оно позволяет рассчитать диаграмму направленности антенной решетки МИМО радиолокационной станции по известным диаграммам направленности антенн приемных и передающих элементов и множителю направленности виртуальной апертуры. Приведена модель антенной решетки МИМО с классическим для нее расположением элементов. Ее множитель направленности получен двумя способами: традиционным в зависимости от расположения элементов виртуальной апертуры; с помощью предложенного в работе выражения. Их разность тождественно равна нулю для всех угловых направлений. Исходя из полученного множителя направленности, рассчитана диаграмма направленности МИМО антенной решетки для случаев использования одинаковых и различных антенн приемных и передающих элементов. Показаны пути снижения уровня боковых лепестков диаграмм направленности МИМО антенных решеток. **Практическая значимость:** полученное в работе выражение учитывает диаграммы направленности антенн приемных и передающих элементов МИМО антенной решетки, что дает возможность анализировать искажение формы диаграммы направленности антенной решетки МИМО радиолокационной станции при сканировании. Вычислительная эффективность приведенного в работе выражения при 20 приемниках и 10 передатчиках составила 6,3 раза.

Ключевые слова – МИМО-радар, диаграмма направленности, множитель решетки, множитель направленности.

Для цитирования: Степанов М. А., Соколов В. С. Соотношения для расчета диаграммы направленности МИМО РЛС при различающихся антеннах приемных и передающих элементов, формирующих ее. *Информационно-управляющие системы*, 2024, № 1, с. 56–63. doi:10.31799/1684-8853-2024-1-56-63, EDN: YHDBHE

For citation: Stepanov M. A., Sokolov V. S. Ratios for calculating the radiation pattern of MIMO radar with different antennas of receiving and transmitting elements forming it. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 56–63 (In Russian). doi:10.31799/1684-8853-2024-1-56-63, EDN: YHDBHE

Введение

Рассмотрим основную идею функционирования МИМО радиолокационных станций (МИМО РЛС) [1–4]. Его можно представить в виде двух частей: МИМО антенная решетка, образуемая совокупностью передающих (Tx) и приемных (Rx) элементов, и многоканальный приемник, формирующий диаграмму направленности (ДН) антенной решетки.

Антенная решетка МИМО состоит из определенного числа передающих (nTx) и приемных (nRx) элементов. Обозначим координаты передающего элемента с порядковым номером k как $\{xT_k, yT_k, zT_k\}$ и приемного элемента с номером i как $\{xR_i, yR_i, zR_i\}$. Передающие элементы излучают взаимно ортогональные (независимые) сигналы [4–7].

Каждый из приемных элементов одновременно принимает совокупность сигналов, прошедших путь от каждого из передающих модулей до блестящих точек объекта наблюдения и обратно. Эта совокупность сигналов с каждого из приемных элементов обрабатывается отдельным каналом приемника [8].

Как правило, МИМО-приемник имеет одинаковую структуру для всех приемных каналов [1, 9, 10]. В каждом канале реализуется набор фильтров, согласованных с сигналом [11], излучаемым каждым из передающих модулей. Это позволяет сформировать на выходах всех приемных каналов $nTx \cdot nRx$ сигналов. Каждый выходной сигнал приемника соответствует определенному направлению распространения электромагнитной волны. Это позволяет, если известно расположение Rx - и Tx -элементов, сформиро-

вать виртуальный массив из $nTx \cdot nRx$ элементов — виртуальную апертуру ММО-антенны. Координаты элементов виртуальной апертуры ММО антенной решетки определяются выражениями [1]

$$\begin{cases} xV_{i,k} = xR_i + xT_k; \\ yV_{i,k} = yR_i + yT_k; \\ zV_{i,k} = zR_i + zT_k. \end{cases} \quad (1)$$

Рассчитанные по (1) координаты являются точками расположения фазовых центров элементов виртуального массива ММО-антенны.

Зная местоположение фазовых центров виртуальной апертуры ММО антенной решетки в декартовой системе координат, можем рассчитать ее множитель направленности по выражению

$$F(\alpha; \theta) = \sum_{i=1}^N \sum_{k=1}^M Am_{i,k} \cdot \exp \left[j\beta (x_{i,k} \times \right. \\ \left. \times [\sin(\alpha_0) - \sin(\alpha)] + y_{i,k} [\sin(\theta_0) - \sin(\theta)] \right], \quad (2)$$

где $(\alpha_0; \theta_0)$ — углы ориентации главного лепестка в плоскости азимута и угла места соответственно; N, M — количество элементов антенной решетки вдоль осей x и y соответственно; $Am_{i,k}$ — комплексная амплитуда сигнала, подводимого к виртуальному элементу антенной решетки с номером i, k ; $\beta = 2\pi/\lambda$ — коэффициент фазы, λ — длина волны излучаемого сигнала; $\{x_{i,k}; y_{i,k}\}$ — координаты виртуального элемента антенной решетки с номером i, k .

Из выражения (2) несложно заметить, что для вычисления множителя направленности ММО антенной решетки в направлении $(\alpha; \theta)$ необходимо рассчитать $nTx \cdot nRx$ комплексных экспонент. При многократном вычислении множителей направленности с мелким шагом по угловым координатам, например при поиске местоположения элементов, обеспечивающих заданные характеристики направленности [12, 13], время вычисления по (2) становится значительным.

Традиционно при анализе направленных свойств антенных решеток ММО-радаров в литературе ограничиваются оценкой характеристик их множителя решетки [1, 2, 14–17]. Выражения, позволяющие учесть ДН антенн приемных и передающих элементов ММО антенной решетки, не приводят. Это ограничивает возможности анализа искажения формы ДН антенной решетки ММО РЛС при сканировании.

Цель настоящей работы — получить соотношения для вычисления ДН антенных решеток ММО РЛС при различающихся антеннах приемных и передающих элементов, формирующих ее.

Соотношения для расчета ДН ММО антенной решетки

Выражение (2) определяет взаимосвязь множителя направленности виртуальной апертуры ММО антенной решетки и расположения ее виртуальных элементов. Получим выражение, позволяющее рассчитать множитель направленности виртуальной апертуры ММО антенной решетки на основе местоположения непосредственно приемных и передающих элементов, не формируя виртуальную апертуру.

Рассмотрим массивы приемных и передающих элементов отдельно. Предположим, что каждый из этих массивов излучает когерентно связанные сигналы. В этом случае каждый из массивов приемных и передающих элементов образует антенную решетку, местоположение элементов которой совпадает с местоположением приемных или передающих элементов соответственно. Будем называть приемной антенную решетку, местоположение элементов которой совпадает с местоположением приемных элементов ММО антенной решетки, а передающей — местоположение элементов которой совпадает с местоположением передающих элементов ММО антенной решетки.

Множители направленности каждой из этих решеток можно рассчитать по выражению (2), подставив координаты элементов и задав амплитудное распределение. Обозначим $F_R(\alpha, \theta)$ и $F_T(\alpha, \theta)$ множитель направленности приемной и передающей антенной решетки соответственно. Фактически множитель направленности представляет собой пространственный спектр распределения излучаемых электромагнитных волн. Он связан с координатами элементов антенной решетки преобразованием, схожим с двумерным преобразованием Фурье.

Согласно системе (1) координаты виртуальных элементов апертуры ММО антенной решетки рассчитываются путем свертки координат приемных и передающих элементов. Тогда с учетом того, что множители направленности и местоположение элементов связаны преобразованием, схожим с преобразованием Фурье, можно воспользоваться теоремой о свертке [18]. В результате получим выражение, связывающее множитель направленности виртуальной апертуры ($F_V(\alpha, \theta)$) и множители направленности приемной и передающей антенн:

$$F_V(\alpha, \theta) = F_R(\alpha, \theta) \cdot F_T(\alpha, \theta). \quad (3)$$

Согласно (3) для расчета множителя направленности виртуальной апертуры ММО антенной решетки достаточно рассчитать множители направленности антенных решеток,

образованных его приемными и передающими элементами. Эта операция требует выполнения $nRx + nTx$ операций вычисления комплексных экспонент для каждого из угловых направлений. Напомним, что для вычисления $F_V(\alpha, \theta)$ непосредственно по виртуальной апертуре МИМО антенной решетки требует $nRx \cdot nTx$ вычислений комплексных экспонент для каждого из угловых положений. Нетрудно заметить, что вычислительная эффективность (снижение времени расчета) при расчете множителя направленности по (3) будет тем выше, чем большее число приемных и передающих элементов содержит МИМО антенная решетка.

Таким образом, получено выражение, позволяющее сократить количество математических операций, требуемых для расчета множителя МИМО антенной решетки. Кроме того, (3) позволяет отдельно анализировать влияние местоположения приемных и передающих элементов МИМО антенной решетки на ее направленные свойства.

Известно, что ДН классической антенной решетки определяется произведением ДН элемента и множителя антенной решетки [19]. На основании (3) несложно записать выражение, определяющее ДН МИМО антенной решетки:

$$f_V(\alpha, \theta) = F_{ER}(\alpha, \theta) \cdot F_R(\alpha, \theta) \cdot F_{ET}(\alpha, \theta) \cdot F_T(\alpha, \theta), \quad (4)$$

где $F_{ER}(\alpha, \theta)$ и $F_{ET}(\alpha, \theta)$ — ДН антенн, используемых для приемных и передающих элементов МИМО антенной решетки соответственно.

В частном случае, если приемные и передающие элементы МИМО антенной решетки используют одинаковые антенны с ДН $F_E(\alpha, \theta) = F_{ER}(\alpha, \theta) = F_{ET}(\alpha, \theta)$, выражение (4) принимает вид

$$f_V(\alpha, \theta) = F_E^2(\alpha, \theta) \cdot F_R(\alpha, \theta) \cdot F_T(\alpha, \theta).$$

Полученные выражения позволяют рассчитать ДН МИМО антенной решетки, не используя координаты элементов ее виртуальной апертуры, при произвольных ДН антенн ее приемных и передающих элементов.

Математическое моделирование множителя решетки

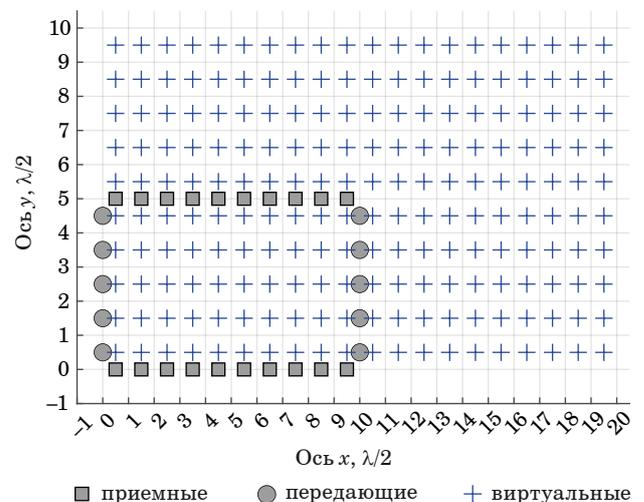
Полученный результат несложно подтвердить математическим моделированием. Для этого составим модель МИМО антенной решетки и рассчитаем ее множитель направленности двумя способами. Первый способ заключается в использовании координат элементов виртуальной апертуры по выражению (2). Второй способ за-

ключается в вычислении множителей направленности приемной и передающей антенных решеток и последующем их перемножении согласно выражению (3).

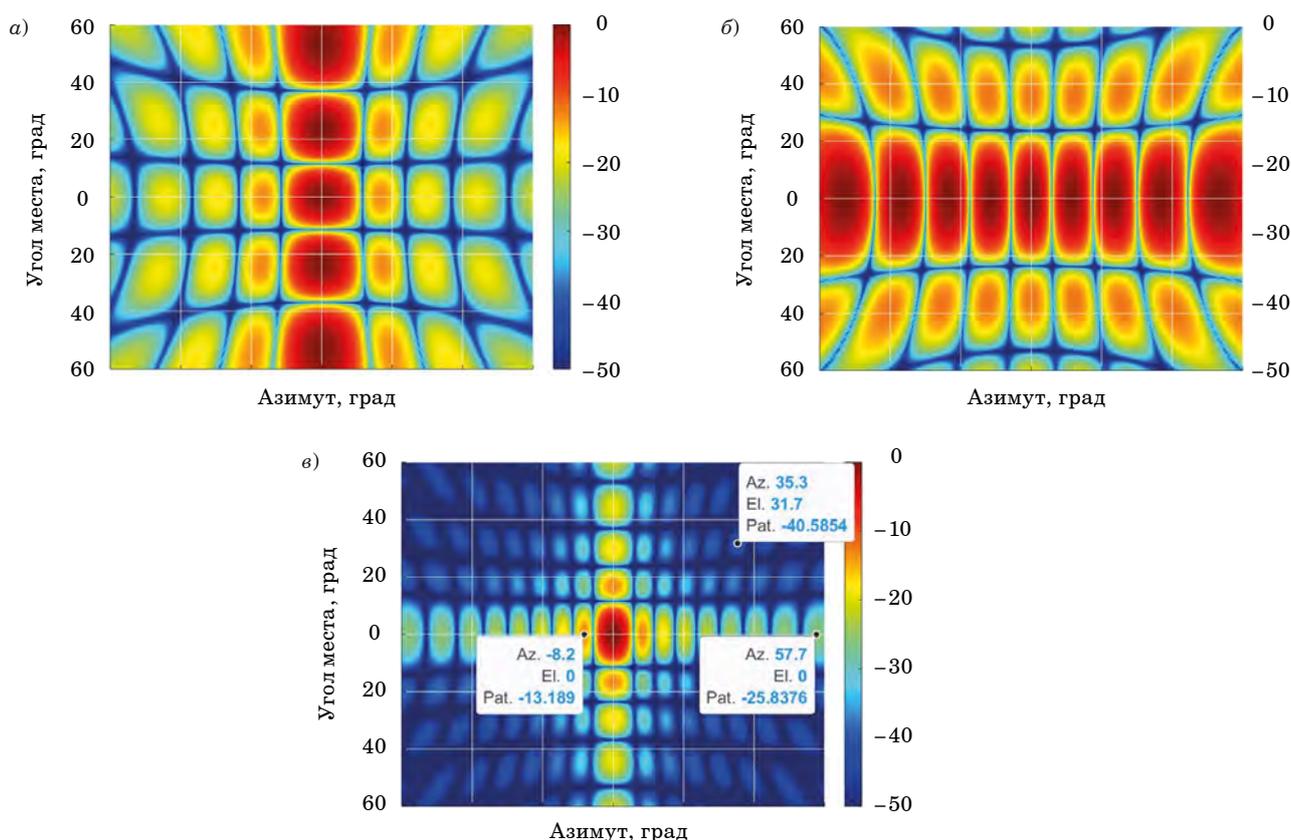
Сформируем модель МИМО антенной решетки. Приемные и передающие элементы расположены с шагом, равным половине длины волны по четырем сторонам прямоугольника [20]. Количество приемных элементов равно 20, они расположены на длинных сторонах прямоугольника. Количество передающих элементов равно 10, они расположены на коротких сторонах прямоугольника. Конфигурация антенной решетки показана на рис. 1. Местоположение элементов виртуальной апертуры определено по соотношению (1). Рассматриваемая конфигурация приемных и передающих элементов приводит к формированию прямоугольной апертуры с элементами, расположенными в узлах прямоугольной сетки с шагом, равным половине длины волны.

Для этой конфигурации элементов, функционирующей на частоте 1 ГГц, по (2) рассчитаны множители направленности приемной и передающей антенн, а также виртуальной апертуры (рис. 2). Кроме этого, на основе зависимостей, изображенных на рис. 2, *a* и *b*, был рассчитан множитель направленности МИМО антенной решетки по соотношению (3). Множители МИМО антенной решетки, рассчитанные по (2) и (3), полностью совпали. Их разность тождественно равна нулю для всех угловых направлений.

Множители направленности приемной и передающей антенн обладают высокими дифракционными лепестками (см. рис. 2). Они имеют периодическую структуру и обусловлены сильным



■ Рис. 1. Конфигурация МИМО антенной решетки
■ Fig. 1. Configuration of the MIMO antenna array



■ **Рис. 2.** Множители направленности приемной антенны (а); передающей антенны (б); виртуальной апертуры (в)
 ■ **Fig. 2.** Directional multipliers: receiving antenna (а); transmitting antenna (б); virtual aperture (в)

разнесением элементов антенн (для приемной – в плоскости угла места, для передающей – в плоскости азимута). Их уровень равен уровню главного лепестка. В множителе направленности ММО антенной решетки, антенны приемных и передающих элементов которой расположены в тех же местах, столь высокие дифракционные лепестки отсутствуют. Максимальный уровень боковых лепестков составляет -13 дБ. Он отмечен на рис. 2, в. Кроме максимального бокового лепестка, на рисунке отмечено два дальних боковых лепестка, уровни которых будут использованы для оценки влияния ДН приемных и передающих элементов.

Множители направленности рассчитаны в диапазоне углов $[-60; 60]$ град для плоскостей азимут и угол места. Шаг, с которым рассчитаны множители направленности, составляет $0,1$ град. Таким образом, общее количество угловых направлений составляет $1\,440\,000$. Время расчета множителя направленности виртуальной апертуры ММО антенной решетки по (2) составило $38,39$ с (результат усреднения по 10 расчетам). При расчете множителя направленности приемной и передающей антенн по (2) с последующим перемножением согласно (3) время рас-

чета составило $6,08$ с (результат усреднения по 10 расчетам). Таким образом, вычислительная эффективность составила $6,3$ раза. Количество вычисляемых комплексных экспонент сократилось в $6,66$ раза. Различия полученной величины вычислительной эффективности и рассчитанной исходя из уменьшения количества вычисляемых комплексных экспонент объясняется временными затратами на перемножение двух полученных множителей направленности.

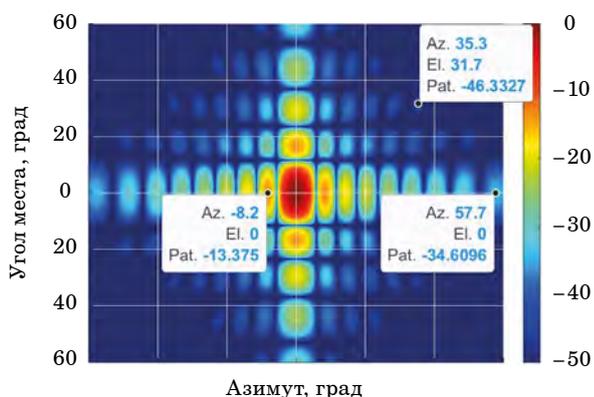
Учет ДН приемных и передающих элементов

Оценим влияние ДН элемента ММО антенной решетки на ее направленные свойства. Согласно (4) ДН ММО антенной решетки формируется путем перемножения ДН антенн приемных элементов, антенн передающих элементов и множителя направленности антенной решетки. Рассмотрим два случая: в первом приемные и передающие элементы имеют антенны с одинаковыми ДН; во втором ДН антенн приемных и передающих элементов различаются.

Одинаковые ДН приемных и передающих элементов

Предположим, что в МИМО антенной решетке, изображенной на рис. 1, приемные и передающие элементы используют одинаковые одиночные печатные резонансные антенны квадратной формы [21]. Ее размеры по каждой из координат составляют половину длины волны. Такие антенны и их свойства хорошо изучены и в настоящее время широко применяются в качестве элементов антенных решеток [22]. Форма сечений ДН таких антенн практически одинакова для плоскостей азимута и угла места. Ширина в обеих плоскостях составляет порядка 90 град.

Диаграмма направленности МИМО антенной решетки, приемные и передающие элементы которой используют одинаковые печатные резонансные антенны, изображена на рис. 3. Она получена путем перемножения множителя направленности виртуальной апертуры (см. рис. 2, б) и ДН антенн приемных и передающих элементов. Видно, что, так как антенна элемента обладает широкой ДН, ее влияние сказывается только на уровне дальних боковых лепестков. На рис. 3 отмечено несколько боковых лепестков. Боковой лепесток множителя направленности виртуальной апертуры с максимальным уровнем ($-8,2$ град в плоскости азимута и 0 град в плоскости угла места) практически не изменился. Уровни дальних боковых лепестков ДН отличаются от уровней тех же лепестков на $6-9$ дБ. Фактически применение одинаковых слабонаправленных антенн для приемных и передающих элементов МИМО антенной решетки позволяет формировать ДН, близкую по форме к множителю направленности ее виртуальной апертуры. То есть направленные свойства в ос-



■ **Рис. 3.** Диаграмма направленности МИМО антенной решетки, приемные и передающие элементы которой используют одинаковые печатные резонансные антенны

■ **Fig. 3.** Radiation pattern of a MIMO antenna array whose receiving and transmitting elements use the same printed resonant antennas

новом определяются расположением приемных и передающих элементов.

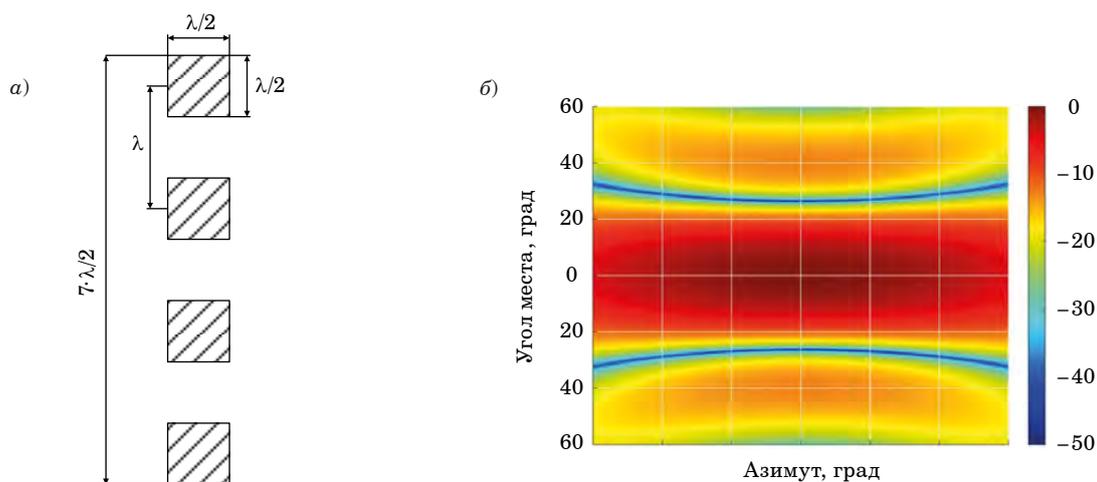
Различные ДН приемных и передающих элементов

Пусть в МИМО антенной решетке, изображенной на рис. 1, антенны приемных и передающих элементов представляют собой антенные решетки из печатных резонансных антенн. Например, подобные антенные решетки применяются как антенны элементов МИМО автомобильных радаров [23]. Каждая из этих решеток сформирована четырьмя печатными резонансными антеннами, расположенными вдоль одной линии и разнесенными на расстояние, равное длине волны. Таким образом, размер антенной решетки каждого из элементов МИМО-решетки равен половине длины волны в одной плоскости и $7/2$ длины волны во второй. Схематичное изображение ее элементов и ДН представлены на рис. 4. Сопоставляя размер антенной решетки элементов и конфигурацию фазовых центров приемных и передающих элементов МИМО антенной решетки (см. рис. 1), несложно заметить, что ориентация антенных решеток приемных и передающих элементов должна быть различной. В противном случае антенны соседних приемных или передающих элементов будут перекрывать друг друга. Для приемных элементов необходимо расположить антенную решетку вертикально (как показано на рис. 4, а), для передающих – горизонтально (повернув изображение на рис. 4, а на 90°). При повороте антенной решетки ее ДН также повернется. Безусловно, при повороте антенной решетки способ запитки ее элементов должен измениться так, чтобы сохранялась поляризация ее излучения.

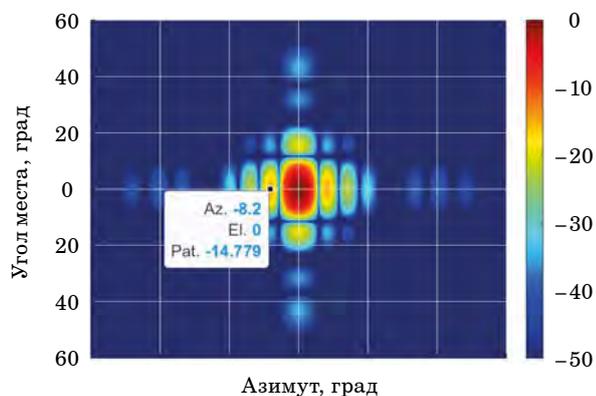
Таким образом, для приемных элементов будет использоваться антенная решетка с широкой ДН в плоскости азимута и узкой в плоскости угла места. Для передающих элементов, наоборот, ДН будет узкой в плоскости азимута и широкой в плоскости угла места.

Диаграмма направленности МИМО антенной решетки, приемные и передающие элементы которой используют различные антенны, изображена на рис. 5. Видно, что применение направленных антенн элементов МИМО антенной решетки приводит к окрасу формы множителя направленности ее виртуальной апертуры произведением ДН антенн приемных и передающих элементов.

Видно, что поскольку ДН антенн приемных и передающих элементов узкие в плоскости угла места и азимута соответственно, происходит интенсивное снижение боковых лепестков множителя направленности. Так, максимальный боковой лепесток множителя направленности



■ **Рис. 4.** Антенная решетка элемента: *a* – схематическое изображение элементов; *б* – диаграмма направленности
 ■ **Fig. 4.** Antenna array of the element: *a* – schematic representation of the elements; *б* – radiation pattern



■ **Рис. 5.** Диаграмма направленности МИМО антенной решетки, приемные и передающие элементы которой используют ортогонально ориентированные антенные решетки
 ■ **Fig. 5.** Radiation pattern of a MIMO antenna array whose receiving and transmitting elements use orthogonally oriented antenna arrays

виртуальной апертуры, смежный с главным лепестком, снизился более чем на 1,5 дБ. Снижение дальних боковых лепестков превышает 20 дБ.

Стоит отметить, что снижение уровня боковых лепестков происходит как в плоскости ази-

мута (благодаря ДН антенн передающих элементов), так и в плоскости угла места (благодаря ДН антенн приемных элементов).

Заключение

В работе получено выражение (3) для расчета множителя направленности антенной решетки МИМО РЛС, позволяющее уменьшить количество математических операций в сравнении с его расчетом по расположению элементов виртуальной апертуры. На его основе записано выражение, позволяющее учесть влияние ДН антенн приемных и передающих элементов МИМО антенной решетки на ее направленные свойства. Оно позволяет рассчитать ДН антенной решетки МИМО РЛС по известным ДН антенн приемных и передающих элементов и множителю направленности виртуальной апертуры.

Показано, что при формировании ДН МИМО антенной решетки есть три степени свободы: множитель направленности виртуальной апертуры, ДН приемных и передающих элементов.

Результаты подтверждены математическим моделированием.

Литература

1. Bergin J., Guerci J. *MIMO radar: Theory and Application*. Artech, 2018. 250 p.
2. Черняк В. С. О новых и старых идеях в радиолокации: МИМО РЛС. *Успехи современной радиоэлектроники*, 2011, № 2, с. 5–20.
3. Sun S., Petropulu A. P., and Poor H. V. MIMO radar for advanced driver-assistance systems and

autonomous driving: Advantages and challenges. *IEEE Signal Processing Magazine*, 2020, vol. 37, iss. 4, pp. 98–117. doi:10.1109/MSP.2020.2978507

4. Davis M. S., Showman G. A., and Lanterman A. D. Coherent MIMO radar: The phased array and orthogonal waveforms. *IEEE Aerospace and Electronic Systems Magazine*, 2014, vol. 29, iss. 8, pp. 76–91. doi:10.1109/MAES.2014.130148

5. Robey F. C., Coutts S., Weikle D., McHarg J. C., and Cuomo K. MIMO radar theory and experimental results. *Conf. Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers*, Pacific Grove, CA, USA, 2004, November 7–10. IEEE, 2004, vol. 1, pp. 300–304. doi:10.1109/ACSSC.2004.1399141
6. Hai Deng. Polyphase code design for Orthogonal Netted Radar systems. *IEEE Transactions on Signal Processing*, 2004, vol. 52, iss. 11, pp. 3126–3135. doi:10.1109/TSP.2004.836530
7. Stoica P., Li J., and Xie Y. On probing signal design for MIMO radar. *IEEE Trans. Signal Process*, 2007, vol. 55, iss. 8, pp. 4151–4161.
8. Bliss D. W., Forsythe K. W. Multiple-input multiple-output (MIMO) radar and imaging: degrees of freedom and resolution. *The Thrity-Seventh Asilomar Conf. on Signals, Systems & Computers*, Pacific Grove, CA, USA, 2003, November 9–12. IEEE, 2003, pp. 54–59. doi:10.1109/ACSSC.2003.1291865
9. Li J., Stoica P. *MIMO radar Signal Processing*. Hoboken, New Jersey, John Wiley & Sons, Inc., 2009. 469 p.
10. Guo Q., Yang L., Xu T., Hu T., Deng Q., and Xu Z. Millimeter-wave MIMO imaging radar with an ultra-high angular resolution of 0.6 degree. *13th Global Symp. on Millimeter-Waves & Terahertz (GSMM)*, Nanjing, China, 2021, May 23–26. IEEE, 2021, pp. 1–3. doi:10.1109/GSMM53250.2021.9511897
11. Jeon Se-Yeon, Ka Min-Ho, Shin Seungha, Kim Munsung, Kim Seok, Kim Sumin, Kim Jeongbae, Dewantari Aulia, Kim Jaehung, Chung Hansup. W-band MIMO FMCW radar system with simultaneous transmission of orthogonal waveforms for high-resolution imaging. *IEEE Transactions on Microwave Theory and Techniques*, 2018, vol. 66, iss. 11, pp. 5051–5064. doi:10.1109/TMTT.2018.2867003
12. Karasev A. S., Stepanov M. A. Genetic algorithm for antenna array thinning with minimization of side lobe level. *XV Intern. Scient.-Tech. Conf. on Actual Problems of Electronic Instrument Engineering (APEIE)*, Novosibirsk, Russian Federation, 2021, November 19–21. IEEE, 2021, pp. 268–272. doi:10.1109/APEIE52976.2021.9647478
13. Karasev A. S., Stepanov M. A. Effect of linear antenna array thinning on its directional pattern parameters. *23rd Intern. Conf. of Young Professionals in Electron Devices and Materials (EDM)*, Altai, Russia, 2022, June 30–July 4. IEEE, 2022, pp. 97–100.
14. Grove R. L. *MIMO radar Systems and Algorithms – Imperfections and Calibration*. Technical University of Denmark, 2022. 213 p.
15. Черняк В. С. *Многопозиционная радиолокация*. М., Радио и связь, 1993. 416 с.
16. Aittomaki T., Koivunen V. Low-complexity method for transmit beamforming in MIMO radars. *IEEE Intern. Conf. on Acoustics, Speech and Signal Processing – ICASSP '07*, Honolulu, HI, USA, 2007. IEEE, 2007, pp. II-305-II-308. doi:10.1109/ICASSP.2007.366233
17. Bekkerman I., Tabrikian J. Target detection and localization using MIMO radars and sonars. *IEEE Transactions on Signal Processing*, 2006, vol. 54, iss. 10, pp. 3873–3883. doi:10.1109/TSP.2006.879267
18. Mauch S. *Introduction to Methods of Applied Mathematics or Advanced Mathematical Methods for Scientists and Engineers*. 2003, 1451 p.
19. Harry L. Van Trees. *Optimum Array Processing. Part IV of Detection, Estimation, and Modulation Theory*. N.Y., John Wiley & Sons, Inc., 2002. 1443 p.
20. Alland S. W., Bordes J. P., Davis C., Murtaza A. Pat. 9869762 USA.
21. Bancroft R. *Microstrip and Printed Antenna Design*. Second Ed. SciTech Publishing Inc., 2009. 266 p.
22. Ogurtsov S., Caratelli D., Song Z. A review of synthesis techniques for phased antenna arrays in wireless communications and remote sensing. *Antenna Propagations*, 2021, Article ID 5514972, pp. 1–20. <https://doi.org/10.1155/2021/5514972>
23. Sun S., Petropulu Athina P., Poor H. Vincent. MIMO radar for advanced driver-assistance systems and autonomus driving. advantages and challenges. *IEEE Signal Processing Magazine*, 2020, vol. 37, iss. 4, pp. 98–117. doi:10.1109/MSP.2020.2978507

UDC 621.396.677

doi:10.31799/1684-8853-2024-1-56-63

EDN: YHDBHE

Ratios for calculating the radiation pattern of MIMO radar with different antennas of receiving and transmitting elements forming it

M. A. Stepanov^a, Dr. Sc., Tech., Associate Professor, orcid.org/0000-0001-6095-1172, m.stepanov@corp.nstu.ruV. S. Sokolov^a, Post-Graduate Student, orcid.org/0009-0001-2210-3970^aNovosibirsk State Technical University, 20, K. Marksa Pr., 630073, Novosibirsk, Russian Federation

Introduction: The synthesis of MIMO antenna arrays differs from the synthesis of classical antenna arrays in that the radiation pattern of the former is formed by a virtual aperture. The virtual aperture is formed by the convolution of the coordinates of physical receiving and transmitting elements, which leads to the formation of a large number of virtual elements. **Purpose:** To obtain relations for calculating the radiation patterns of antenna arrays of MIMO radar with different antennas of receiving and transmitting elements forming it. **Results:** We obtain an expression for calculating the antenna arrays directivity multiplier of the MIMO radar, which allows

us to reduce the number of mathematical operations in comparison with the calculation of the virtual aperture elements arrangement. On the basis of this expression we receive the expression that make it possible to take into account the influence of antenna radiation patterns of receiving and transmitting elements of MIMO antenna array on its directional properties. It allows us to calculate the radiation pattern of the MIMO antenna array of a radar according to the known radiation patterns of antennas of receiving and transmitting elements and the directional multiplier of the virtual aperture. We present a model of a MIMO antenna array with a classical arrangement of elements. Its directivity multiplier is obtained in two ways: the traditional way using the arrangement of virtual aperture elements and by using the expression proposed in the paper. Their difference is identically equal to zero for all angular directions. On the basis of the obtained directivity multiplier we calculate the radiation pattern of MIMO antenna array for the cases when the same and different antennas of receiving and transmitting elements are used. We demonstrate the ways to reduce the level of side lobes of MIMO antenna arrays radiation pattern. **Practical relevance:** The expression obtained in the paper takes into account the radiation patterns of the receiving and transmitting elements of the MIMO antenna array, which makes it possible to analyze the distortion of the shape of the MIMO radar antenna array pattern during scanning. The computational efficiency of the expression given in the paper and involving 20 receivers and 10 transmitters is 6.3 times.

Keywords – MIMO radar, radiation pattern, antenna array multiplier, directivity multiplier.

For citation: Stepanov M. A., Sokolov V. S. Ratios for calculating the radiation pattern of MIMO radar with different antennas of receiving and transmitting elements forming it. *Informatsionno-upravliayushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 56–63 (In Russian). doi:10.31799/1684-8853-2024-1-56-63, EDN: YHDBHE

Reference

- Bergin J., Guerci J. *MIMO radar: Theory and Application*. Artech, 2018. 250 p.
- Chernyak V. S. About new and old ideas in radar: MIMO radars. *Uspekhi sovremennoj radioelektroniki*, 2011, no. 2, pp. 5–20 (In Russian).
- Sun S., Petropulu A. P., and Poor H. V. MIMO radar for advanced driver-assistance systems and autonomous driving: Advantages and challenges. *IEEE Signal Processing Magazine*, 2020, vol. 37, iss. 4, pp. 98–117. doi:10.1109/MSP.2020.2978507
- Davis M. S., Showman G. A., and Lanterman A. D. Coherent MIMO radar: The phased array and orthogonal waveforms. *IEEE Aerospace and Electronic Systems Magazine*, 2014, vol. 29, iss. 8, pp. 76–91. doi:10.1109/MAES.2014.130148
- Robey F. C., Coumts S., Weikle D., McHarg J. C., and Cuomo K. MIMO radar theory and experimental results. *Conf. Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers*. IEEE, 2004, vol. 1, pp. 300–304. doi:10.1109/ACSSC.2004.1399141
- Hai Deng. Polyphase code design for Orthogonal Netted Radar systems. *IEEE Transactions on Signal Processing*, 2004, vol. 52, iss. 11, pp. 3126–3135. doi:10.1109/TSP.2004.836530
- Stoica P., Li J., and Xie Y. On probing signal design for MIMO radar. *IEEE Trans. Signal Process*, 2007, vol. 55, iss. 8, pp. 4151–4161.
- Bliss D. W., Forsythe K. W. Multiple-input multiple-output (MIMO) radar and imaging: degrees of freedom and resolution. *The Thirty-Seventh Asilomar Conf. on Signals, Systems & Computers*. IEEE, 2003, pp. 54–59. doi:10.1109/ACSSC.2003.1291865
- Li J., Stoica P. *MIMO radar Signal Processing*. Hoboken, New Jersey, John Wiley & Sons, Inc., 2009. 469 p.
- Guo Q., Yang L., Xu T., Hu T., Deng Q., and Xu Z. Millimeter-wave MIMO imaging radar with an ultra-high angular resolution of 0.6 degree. *13th Global Symp. on Millimeter-Waves & Terahertz (GSMM)*. IEEE, 2021, pp. 1–3. doi:10.1109/GSMM53250.2021.9511897
- Jeon Se-Yeon, Ka Min-Ho, Shin Seungha, Kim Munsung, Kim Seok, Kim Sumin, Kim Jeongbae, Dewantari Aulia, Kim Jaeheung, Chung Hansup. W-band MIMO FMCW radar system with simultaneous transmission of orthogonal waveforms for high-resolution imaging. *IEEE Transactions on Microwave Theory and Techniques*, 2018, vol. 66, iss. 11, pp. 5051–5064. doi:10.1109/TMTT.2018.2867003
- Karasev A. S., Stepanov M. A. Genetic algorithm for antenna array thinning with minimization of side lobe level. *XV Intern. Scient.-Tech. Conf. on Actual Problems of Electronic Instrument Engineering (APEIE)*. IEEE, 2021, pp. 268–272. doi:10.1109/APEIE52976.2021.9647478
- Karasev A. S., Stepanov M. A. Effect of linear antenna array thinning on its directional pattern parameters. *23rd Intern. Conf. of Young Professionals in Electron Devices and Materials (EDM)*, 2022. IEEE, 2022, pp. 97–100.
- Grove R. L. *MIMO radar Systems and Algorithms – Imperfections and Calibration*. Technical University of Denmark, 2022. 213 p.
- Chernyak V. S. *Mnogopozitsionnaya radiolokaciya* [Multi-position radar]. Moscow, Radio i svyaz' Publ., 1993. 416 p. (In Russian).
- Aittomaki T., Koivunen V. Low-complexity method for transmit beamforming in MIMO radars. *IEEE Intern. Conf. on Acoustics, Speech and Signal Processing – ICASSP '07*. IEEE, 2007, pp. II-305–II-308. doi:10.1109/ICASSP.2007.366233
- Bekkerman I., Tabrikian J. Target detection and localization using MIMO radars and sonars. *IEEE Transactions on Signal Processing*, 2006, vol. 54, iss. 10, pp. 3873–3883. doi:10.1109/TSP.2006.879267
- Mauch R. *Introduction to Methods of Applied Mathematics or Advanced Mathematical Methods for Scientists and Engineers*. 2003. 1451 p.
- Harry L. Van Trees. *Optimum Array Processing. Part IV of Detection, Estimation, and Modulation Theory*. N.Y., John Wiley & Sons, Inc., 2002. 1443 p.
- Alland S. W., Bordes J. P., Davis C., Murtaza A. Pat. 9869762 USA.
- Bancroft R. *Microstrip and Printed Antenna Design*. Second Ed. SciTech Publishing Inc., 2009. 266 p.
- Ogurtsov S., Caratelli D., Song Z. A review of synthesis techniques for phased antenna arrays in wireless communications and remote sensing. *Antenna Propagations*, 2021, ArticleID 5514972, pp. 1–20. https://doi.org/10.1155/2021/5514972
- Sun S., Petropulu Athina P., Poor H. Vincent. MIMO radar for advanced driver-assistance systems and autonomous driving: advantages and challenges. *IEEE Signal Processing Magazine*, 2020, vol. 37, iss. 4, pp. 98–117. doi:10.1109/MSP.2020.2978507

БАЛОНИН
Николай
Алексеевич



Профессор кафедры вычислительных систем и сетей Санкт-Петербургского государственного университета аэрокосмического приборостроения. В 1982 году окончил Ленинградский электротехнический институт им. В. И. Ульянова (Ленина) по специальности «Автоматика и телемеханика». В 2008 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором более 100 научных публикаций, в том числе пяти монографий. Область научных интересов — теория динамических систем, теория идентификации, теория операторов, теория матриц, вычислительные методы, интернет-робототехника, интернет-книги с исполняемыми алгоритмами, научные социальные сети. Эл. адрес: korbendfs@mail.ru

БРЫЛЕВ
Олег
Александрович



Аспирант отделения автоматизации и робототехники Национального исследовательского Томского политехнического университета. В 2023 году окончил магистратуру Национального исследовательского Томского политехнического университета по специальности «Мехатроника и робототехника». Является автором девяти научных публикаций. Область научных интересов — мобильная робототехника, навигация мобильных роботов. Эл. адрес: oab12@tpu.ru

КУШНАРЕВ
Олег
Юрьевич



Магистрант отделения автоматизации и робототехники Национального исследовательского Томского политехнического университета. В 2023 году окончил Национальный исследовательский Томский политехнический университет по специальности «Мехатроника и робототехника». Является автором двух научных публикаций. Область научных интересов — анализ данных, машинное обучение, мобильные роботы. Эл. адрес: okushnarev@icloud.com

БЕЛЯЕВ
Александр
Сергеевич



Старший преподаватель отделения автоматизации и робототехники Национального исследовательского Томского политехнического университета. В 2017 году окончил магистратуру Национального исследовательского Томского политехнического университета по специальности «Мехатроника и робототехника». В 2023 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором более 40 научных публикаций и двух патентов на изобретения. Область научных интересов — теория автоматического управления, мобильная робототехника, навигация мобильных роботов, методы интеллектуального управления. Эл. адрес: asb22@tpu.ru

ГРУЗДЕВ
Николай
Валентинович



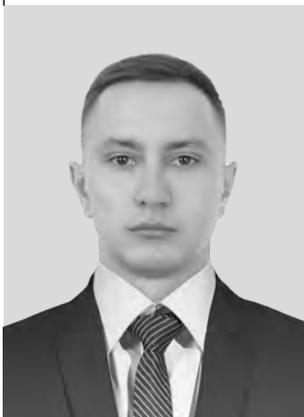
Старший научный сотрудник отдела Военно-космической академии им. А. Ф. Можайского, Санкт-Петербург. В 1994 году окончил Военно-космическую академию им. А. Ф. Можайского по специальности «Электроснабжение космических комплексов». В 2006 году защитил диссертацию на соискание ученой степени кандидата военных наук. Является автором 35 научных публикаций. Область научных интересов — моделирование и оптимизация управления движением ракет-носителей и космических аппаратов. Эл. адрес: NikGruzdev@rambler.ru

ЛИПАТНИКОВ
Валерий
Алексеевич



Профессор, старший научный сотрудник Военной академии связи им. Маршала Советского Союза С. М. Буденного, Санкт-Петербург, заслуженный изобретатель РФ, член-корреспондент РАЕН. В 1974 году окончил Военную академию связи им. Маршала Советского Союза С. М. Буденного по специальности «Специальная радиотехника». В 2000 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором 267 научных публикаций и 80 патентов на изобретения. Область научных интересов — теория многоуровневой иерархической радиоэлектронной защиты, безопасности связи и информации инфотелекоммуникационных сетей. Эл. адрес: lipatnikovanl@mail.ru

**МЕЛЕХОВ
Кирилл
Витальевич**



Адъюнкт Военной академии связи им. Маршала Советского Союза С. М. Буденного, Санкт-Петербург.

В 2013 году окончил Краснодарский филиал Военной академии связи им. С. М. Буденного по специальности «Комплексная защита объектов информатизации».

Является автором 20 научных публикаций и одного патента на изобретение.

Область научных интересов – информационная безопасность, компьютерная безопасность, защита информации от несанкционированного доступа, способы контроля уязвимостей и управление безопасностью информационно-телекоммуникационных, информационно-вычислительных и распределенных информационных сетей.

Эл. адрес: kirill_melehov@bk.ru

**СЕРГЕЕВ
Александр
Михайлович**



Доцент кафедры вычислительных систем и сетей Санкт-Петербургского государственного университета аэрокосмического приборостроения.

В 2004 году окончил Санкт-Петербургский государственный университет аэрокосмического приборостроения по специальности «Вычислительные машины, комплексы, системы и сети».

В 2020 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором 35 научных публикаций.

Область научных интересов – численные методы, теория вычислительных процессов, проектирование специализированных процессоров.

Эл. адрес: asklab@mail.ru

**СОКОЛОВ
Вадим
Сергеевич**



Аспирант кафедры радиоприемных и радиопередающих устройств, инженер-электроник Центра радиотехнических устройств Новосибирского государственного технического университета.

В 2023 году окончил Новосибирский государственный технический университет по направлению «Радиотехника».

Является автором восьми научных публикаций и одного патента на изобретение.

Область научных интересов – антенны, антенные решетки, прореженные антенные решетки.

Эл. адрес: vady.sokol@gmail.com

**МИЛОСЕРДОВ
Дмитрий
Игоревич**



Старший научный сотрудник Санкт-Петербургского Федерального исследовательского центра РАН.

В 2018 году окончил Университет ИТМО по специальности «Информационная безопасность».

В 2022 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором 13 научных публикаций.

Область научных интересов – нейронные сети, прогнозирование временных рядов.

Эл. адрес: dmmil94@yandex.ru

**СЕРГЕЕВ
Михаил
Борисович**



Профессор, заведующий кафедрой вычислительных систем и сетей Санкт-Петербургского государственного университета аэрокосмического приборостроения, почетный работник высшего профессионального образования РФ.

В 1980 году окончил Ленинградский электротехнический институт им. В. И. Ульянова (Ленина) по специальности «Электронные вычислительные машины».

В 2001 году защитил диссертацию на соискание ученой степени доктора технических наук.

Является автором более 100 научных публикаций и 14 патентов на изобретения.

Область научных интересов – теория разрядных вычислений, методы проектирования спец-процессоров для систем контроля и управления и др.

Эл. адрес: mbse@mail.ru

**СТЕПАНОВ
Максим
Андреевич**



Доцент, заведующий кафедрой радиоприемных и радиопередающих устройств Новосибирского государственного технического университета.

В 2005 году окончил Новосибирский государственный технический университет по направлению «Радиотехника».

В 2019 году защитил диссертацию на соискание ученой степени кандидата технических наук.

Является автором 132 научных публикаций и восьми патентов на изобретения.

Область научных интересов – моделирование сложной радиоэлектронной обстановки в реальном масштабе времени, антенны, антенные решетки, прореженные антенные решетки.

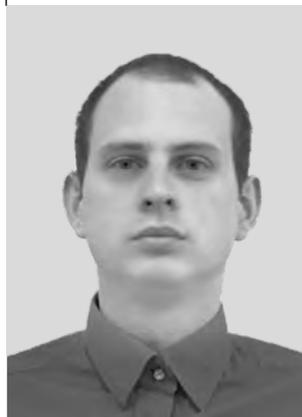
Эл. адрес: m.stepanov@corp.nstu.ru

**ТКАЧЕВ
Дмитрий
Федорович**



Начальник научно-исследовательского отдела НИЦ Военной академии связи им. Маршала Советского Союза С. М. Буденного, Санкт-Петербург. В 2010 году окончил Ставропольский военный институт связи ракетных войск по специальности «Радиосвязь, радиовещание и телевидение». В 2015 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором 115 научных публикаций и 15 свидетельств о регистрации электронных ресурсов. Область научных интересов – развитие и совершенствование средств и комплексов связи, испытания средств и комплексов связи, инфокоммуникационные сети специального назначения. Эл. адрес: dimas.portnoy@inbox.ru

**ШЕВЧЕНКО
Александр
Александрович**



Научный сотрудник научно-исследовательского центра Военной академии связи им. Маршала Советского Союза С. М. Буденного, Санкт-Петербург. В 2015 году окончил Рязанский государственный радиотехнический университет по специальности «Компьютерная безопасность». Является автором 42 научных публикаций. Область научных интересов – компьютерная безопасность, информационная безопасность, способы контроля уязвимостей и управления безопасностью информационно-вычислительных, информационно-телекоммуникационных и распределенных информационных сетей. Эл. адрес: alex_pavel1991@mail.ru

**ШУВАЕВ
Федор
Леонидович**



Начальник лаборатории Военно-космической академии им. А. Ф. Можайского, Санкт-Петербург. В 2010 году окончил Военно-космическую академию им. А. Ф. Можайского по специальности «Автоматизированные системы управления». В 2019 году защитил диссертацию на соискание ученой степени кандидата технических наук. Является автором 15 научных публикаций. Область научных интересов – теория графов, математическая статистика, прогнозирование временных рядов, теория распознавания образов. Эл. адрес: cadetfed@mail.ru

ПАМЯТКА ДЛЯ АВТОРОВ

Поступающие в редакцию статьи проходят обязательное рецензирование.

При наличии положительной рецензии статья рассматривается редакционной коллегией. Принятая в печать статья направляется автору для согласования редакторских правок. После согласования автор представляет в редакцию окончательный вариант текста статьи.

Процедуры согласования текста статьи могут осуществляться как непосредственно в редакции, так и по e-mail (ius.spb@gmail.com).

При отклонении статьи редакция представляет автору мотивированное заключение и рецензию, при необходимости доработать статью – рецензию.

Редакция журнала напоминает, что ответственность за достоверность и точность рекламных материалов несут рекламодатели.