


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

ИНФОРМАЦИОННО- УПРАВЛЯЮЩИЕ СИСТЕМЫ

НАУЧНЫЙ ЖУРНАЛ



3(136)/2025

3(136)/2025

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

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

A. Tyugashev,

Dr. Sc., Professor, Samara, Russia

Z. Yuldashev

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: ius.spb@gmail.com

Tel.: +7 - 812 494 70 02

INFORMATION PROCESSING AND CONTROL**Losev A. G., Medvedev I. A.***Method of minimizing the duration of observations and mathematical extrapolation models at small data volumes*

2

Verzun N. A., Kolbanev M. O., Salieva A. R.*Multi-agent ensemble algorithm for acoustic recognition of malfunctioning of autonomous technological equipment*

14

Lebedev I. S.*Sequential information processing using adaptive pattern analysis in assessing the state of systems*

25

INFORMATION AND CONTROL SYSTEMS**Mikov A. I., Mikov A. A.***Mathematical model of a search sensor network with connectivity control*

37

HARDWARE AND SOFTWARE RESOURCES**Alpatova M. V., Rudyak Y. V.***Optimization of virtual object placement in extended reality using dynamic programming*

49

INFORMATION CHANNELS AND MEDIUM**Pavlov V. A., Belov A. A., Shariaty F.***Clustering of users in cognitive control system of reflective intelligent surface for 5G/6G communication systems*

59

CHRONICLES AND INFORMATION*In memory of N. A. Balonin*

69

INFORMATION ABOUT THE AUTHORS

70

3(136)/2025

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. Буздалов,
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
А. А. Мюллери,
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. Суткин,
д-р наук, доцент, Джокьякарта, Индонезия
А. А. Тюгашев,
д-р техн. наук, проф., Самара, РФ
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. Шалыто,
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

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

ОБРАБОТКА ИНФОРМАЦИИ И УПРАВЛЕНИЕ

Лосев А. Г., Медведев И. А.

Метод минимизации продолжительности наблюдений
и математические модели экстраполяции при малых объемах данных 2

Верзун Н. А., Колбанев М. О., Салиева А. Р.

Многоагентный ансамблевый алгоритм акустического
распознавания нарушений работоспособности автономного
технологического оборудования 14

Лебедев И. С.

Обработка информационных последовательностей
с использованием адаптивного анализа сегментов при оценке
состояния систем 25

ИНФОРМАЦИОННО-УПРАВЛЯЮЩИЕ СИСТЕМЫ

Миков А. И., Миков А. А.

Математическая модель поисковой сенсорной сети с управлением
связностью 37

ПРОГРАММНЫЕ И АППАРАТНЫЕ СРЕДСТВА

Алпатова М. В., Рудяк Ю. В. Оптимизация размещения виртуальных
объектов в расширенной реальности с использованием
динамического программирования 49

ИНФОРМАЦИОННЫЕ КАНАЛЫ И СРЕДЫ

Павлов В. А., Белов А. А., Шариати Ф.

Кластеризация абонентов в когнитивной системе управления
реконфигурируемой интеллектуальной поверхностью
для систем связи 5G/6G 59

ХРОНИКА И ИНФОРМАЦИЯ

Памяти

Николая Алексеевича Балонина 69

СВЕДЕНИЯ ОБ АВТОРАХ

70

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 05.05.25. Подписано в печать 18.06.25. Дата выхода в свет: 20.06.2025.

Формат 60×84/8. Гарнитура CentSchbkCyrill BT. Печать цифровая.

Усл. печ. л. 8,5. Уч.-изд. л. 11,7. Тираж 1000 экз (1-й завод 50 экз.). Заказ № 195.

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, 2025



Метод минимизации продолжительности наблюдений и математические модели экстраполяции при малых объемах данных

А. Г. Лосев^а, доктор физ.-мат. наук, профессор, orcid.org/0000-0002-1072-8375, alexander.losev@volsu.ru

И. А. Медведев^а, аспирант, orcid.org/0009-0001-2536-4359

^аВолгоградский государственный университет, Университетский пр., 100, Волгоград, 400062, РФ

Введение: экстраполяция значений временных рядов с малым объемом данных — задача актуальная, особенно в областях, где требуется быстрое принятие решений на основе ограниченной информации. Одной из ключевых проблем является нахождение наименьшего отрезка исторических данных, достаточного для построения точного прогноза последующих значений временного ряда. **Цель:** разработать метод минимизации временных наблюдений, позволяющий осуществлять экстраполяцию будущих значений с заранее заданной точностью, и метод синтеза данных на основе параметров математической модели прогнозирования. **Результаты:** во-первых, разработан метод определения минимальных отрезков эффективного прогнозирования. Метод предполагает наличие обучающей выборки и основан на анализе динамики изменения значений временных рядов вокруг их максимума, что позволило автоматически определять отрезки данных минимальной длины, необходимые для построения прогнозов с заранее заданной точностью. Во-вторых, разработан метод формирования синтетических данных, использующий варьирование параметров математической модели. Синтез данных позволил повысить эффективность обучения искусственных нейронных сетей. Указанные методы были применены в анализе временных рядов напряжения микробных топливных элементов для оценки параметра загрязнения сточных вод — биохимического потребления кислорода. В результате удалось сократить время прогнозирования данного параметра с пяти суток до 12,68 часа с относительной погрешностью 8,1 %. **Практическая значимость:** предложенные методы, используемые в ходе экологического мониторинга, позволяют оперативно оценивать загрязнение воды и оптимизировать процессы очистки сточных вод.

Ключевые слова — математические модели экстраполяции, синтез данных, временные ряды, искусственная нейронная сеть, логнормальное распределение, микробный топливный элемент, биохимическое потребление кислорода.

Для цитирования: Лосев А. Г., Медведев И. А. Метод минимизации продолжительности наблюдений и математические модели экстраполяции при малых объемах данных. *Информационно-управляющие системы*, 2025, № 3, с. 2–13. doi:10.31799/1684-8853-2025-3-2-13, EDN: RAJEBP

For citation: Losev A. G., Medvedev I. A. Method of minimizing the duration of observations and mathematical extrapolation models at small data volumes. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 2–13 (In Russian). doi:10.31799/1684-8853-2025-3-2-13, EDN: RAJEBP

Введение

Разработка моделей экстраполяции имеет большую историю и не теряет своей актуальности до настоящего времени. В ряде случаев их практическое применение имеет ключевое значение для принятия обоснованных решений. В большинстве исследований, посвященных анализу временных рядов, рассматриваются вопросы выбора оптимальной модели прогнозирования, т. е. получения прогноза последующих значений с удовлетворительной погрешностью. Одной из важнейших задач при прогнозировании временных данных является определение начального участка последовательности, который будет использоваться для построения прогноза. Наиболее интересно определение такого отрезка данных, который не только позволяет адекватно отражать динамику исследуемого процесса, но и одновременно обеспечивает минимизацию продолжительности наблюдений, т. е. имеет минимальную

длину относительно начальной точки. Далее будем называть его минимальным отрезком эффективного прогнозирования.

Различные методы определения минимальных отрезков эффективного прогнозирования рассматривались, например, в задачах сокращения продолжительности экспериментов по кинетике нагревания [1], оценки режимных значений временных рядов скорости ветра [2], анализа геофизических данных [3] и т. д. Эти методы, включая перебор отрезков фиксированной длины и усечение начальных данных, имеют существенные ограничения. Более эффективным решением является выявление характерных точек временных рядов, которые отражают ключевые изменения в данных и повышают точность экстраполяции. Характерные точки могут быть выявлены непосредственно из данных. Например, в работе [4] предложен статистический алгоритм на основе относительной дивергенции Пирсона для обнаружения точек изменений. Существуют

и другие способы определения характерных точек [5–7]. Автоматизация этого процесса возможна с использованием машинного обучения [8, 9]. Также предлагались методы сегментирования данных и выбора оптимальных моделей для локальных участков рядов [10]. Применение характерных точек и информативных сегментов для экстраполяции продемонстрировано в исследованиях [9, 11, 12]. Отметим, что анализ сегментов рядов важен не только для экстраполяции, но и в задачах классификации временных рядов и определения синхронизации их участков [13, 14].

Таким образом, проблема определения минимальных отрезков эффективного прогнозирования актуальна и применима в различных областях, например в экологии. Низкое качество воды — глобальная проблема современного человечества. Для оценки загрязненности воды широко используется показатель биохимического потребления кислорода (БПК; Biochemical Oxygen Demand, BOD), который количественно определяет уровень биоразлагаемых органических загрязнителей. Однако стандартный тест БПК₅ требует не менее пяти дней измерений при температуре 20 °C [15], что ограничивает его применение для мониторинга в реальном времени.

Для повышения эффективности определения БПК₅ разрабатывались различные биосенсоры, включая микробные топливные элементы (МТЭ), — устройства, преобразующие энергию органических веществ в электрический ток благодаря экзоэлектрогенным бактериям. Временные ряды напряжения МТЭ отражают динамику электрической активности системы как ответ на изменения в составе сточных вод. Общий заряд, рассчитанный по рядам напряжения, находится в линейной зависимости от БПК₅, так как количество электронов, переданных на анод, пропорционально концентрации органических веществ. Метод раннего определения БПК₅, основанный на линейной зависимости между общим зарядом и концентрацией БПК₅, может сократить время анализа до 0,5–4 сут с относительной погрешностью в пределах 10 % [16]. Искусственные нейронные сети (ИНС) могут применяться для прогноза напряжения МТЭ на основе значений напряжения, измеренных за 8–24 ч [17]. Это позволяет, если опираться на предсказанную динамику электрической активности системы, косвенно оценивать БПК₅ через линейную зависимость с рассчитанным общим зарядом. Однако применение ИНС предполагало использование фиксированного размера входных данных для всех рядов напряжения и разработку нескольких моделей ИНС для разного входного времени. При этом оптимальное время измерения может варьироваться для разных рядов напряжения. Это связано с тем, что динамика изменения напряжения может отличаться в зависимости от содержимого образцов воды.

Существующие математические модели, такие как модель Моно, не подходят для описания исследуемых функций напряжения [18, 19]. Численное моделирование требует создания новых моделей с учетом множества параметров. В работе предложен способ, близкий к суррогатному моделированию, использующий аппроксимацию и экстраполяцию функций напряжения семейством функций с малым числом параметров. На основе параметров этого семейства был предложен метод формирования синтетических данных, создающих обучающий набор, что позволило применять ИНС для улучшения прогнозирования и учета сложных зависимостей.

Условия на класс функций.

Для проблематики, связанной с определением минимальных отрезков эффективного прогнозирования, необходимо ввести некоторые обозначения и условия. Предположим, что мы имеем дело с набором временных рядов, которые можно интерпретировать как непрерывные функции, зависящие от параметров, описывающих динамику исследуемого процесса.

Обозначим через $V([a, b], A)$ некоторое подмножество неотрицательных непрерывных на $[a, b]$ функций, зависящих от параметра $\alpha \in A$, вообще говоря, бесконечномерного. Будем предполагать, что для любой функции $v(x, \alpha) \in V([a, b], A)$ отрезок $[a, b]$ можно разбить на два участка монотонности $[a, x_{\max}]$ и $[x_{\max}, b]$, т. е. существует единственный глобальный максимум $v_{\max}$, достигаемый в точке $x_{\max}$. Под $V([a_c, b_c], A)$ будем понимать множество сужений функций из $V([a, b], A)$ на отрезок $[a_c, b_c]$.

Пусть далее $U([a, b], S)$ — множество функций, заданных на $[a, b]$, зависящих от конечномерного вектора параметров $\mathbf{s}(\alpha, c)$ и обеспечивающих аппроксимацию функций из $V([a_c, b_c], A)$ с заданной точностью. Поясним последний тезис. Предположим, что нам задан параметр точности ε . Если для любой функции $v(x, \alpha) \in V([a_c, b_c], A)$ найдется функция $u(x, \mathbf{s}(\alpha, c)) \in U([a, b], S)$ такая, что $\rho_{[a_c, b_c]}(v, u) \leq \varepsilon$, то будем говорить, что $U([a, b], S)$ обеспечивает аппроксимацию функций из $V([a_c, b_c], A)$ с точностью ε . Здесь $\rho_{[a_c, b_c]}(v, u)$ — некоторая мера близости функций v и u на отрезке $[a_c, b_c]$. В частности, это может быть метрика какого-нибудь функционального пространства, например:

$$\rho_{[a_c, b_c]}(v, u) = \|v(x, \alpha) - u(x, \mathbf{s}(\alpha, c))\|_{L^2_{[a_c, b_c]}}. \quad (1)$$

Введенные обозначения и условия на класс функций позволяют формализовать задачу определения минимальных отрезков эффективного прогнозирования.

Метод определения минимальных отрезков эффективного прогнозирования

Первой задачей, решаемой в рамках данного исследования, является разработка метода нахождения отрезка $[a_c, b_c] \subset [a, b]$, минимизирующего величину $b_c - a$ и такого, что выполнено условие $p_{[a,b]}(v, u) \leq \varepsilon_1$. Здесь $p_{[a,b]}(v, u)$ — некоторая мера близости функций v и u на отрезке $[a, b]$, а ε_1 — точность экстраполяции. Например, в качестве $p_{[a,b]}(v, u)$ можно использовать величину

$$p_{[a,b]}(v, u) = \frac{1}{b-a} \left\| 1 - \frac{u(x, s(\alpha, c))}{v(x, \alpha)} \right\|_{L_{1[a,b]}}. \quad (2)$$

Введем параметр c , принимающий значения в интервале $(0, 1)$. Каждому такому c поставим в соответствие точку $x_c \in (x_{\max}, b]$, в которой $v(x_c, \alpha) = cv_{\max}$. Если такой точки не существует, т. е. если для любого $x \in (x_{\max}, b]$ выполняется $v(x, \alpha) > cv_{\max}$, то положим x_c равной b . При таком определении x_c для любого $x \in (x_{\max}, x_c]$ будет выполнено $v(x, \alpha) \geq cv_{\max}$, что следует из монотонного убывания функций на отрезке $[x_{\max}, b]$.

Зафиксируем некоторую $v(x, \alpha) \in V([a, b], A)$ и рассмотрим множество отрезков $[a, x_c] \subset [a, b]$. Каждому отрезку $[a, x_c]$ можно поставить в соответствие функцию $u(x, s(\alpha, c)) \in U([a, b], S)$, которая аппроксимирует $v(x, \alpha)$ с заданной точностью, например, в метрике (1). Векторы параметров $s(\alpha, c)$, полученные при аппроксимации $v(x, \alpha)$ на $[a, x_c]$, позволяют восстановить значения $u(x, s(\alpha, c))$ на отрезок $[a, b]$. Таким образом, на $[a, b]$ может быть получено множество $p_{[a,b]}(v, u, c)$ значений мер близости функций v и u [например, по формуле (2)], где c указывает, что параметры аппроксимации подбирались на $[a, x_c]$. На самом деле, в дальнейшем нами будут рассматриваться не произвольные пары (v, u) , а произвольная v и аппроксимирующая u . Стало быть, на основе значений параметра c может быть получено множество отрезков для определения параметров аппроксимирующих функций и множество значений мер близости функций на $[a, b]$. Рассмотрим какую-нибудь агрегатную функцию, например: $\bar{p}_{[a,b]}(c) = \sup_{v, u} (p_{[a,b]}(v, u, c))$. Максимальное c , при котором выполнено $\bar{p}_{[a,b]}(c) \leq \varepsilon_1$, будем обозначать c_r^* и называть оптимальным параметром формирования правых границ отрезков эффективного прогнозирования. А оптимальные правые границы отрезков каждой функции множества $V([a, b], A)$ обозначим как $x_{c_r}^*$. Аналогичным образом могут определяться $x_{c_l}^*$ — оптимальные левые границы отрезков эффективного прогнозирования и параметр формирования левых границ этих отрезков c_l^* .

В приложениях данные обычно рассматриваются в дискретной форме. Пусть на сетке: $\mathbf{x} = x_j$, где $x_j = a + (j-1)h, j = 1, 2, \dots, n$, с равномерным шагом задано множество из m функций $v_i(\mathbf{x})$, где $i = 1, 2, \dots, m$. Значения функций можно представить в виде матрицы $\mathbf{V}$ с элементами $v_i(x_j)$. Назовем данный набор из m функций обучающим. Поскольку каждая функция $v_i(\mathbf{x})$ имеет единственный максимум, обозначим $\mathbf{C}$, элементы которой имеют вид, представленный выражением

$$c_{ij} = \frac{v_i(x_j)}{\max_{j=1,2,\dots,n} (v_i(x_j))}, \quad i = 1, 2, \dots, m; j = 1, 2, \dots, n. \quad (3)$$

Для каждой i -й строки в матрице $\mathbf{C}$ определим номер столбца, в котором достигается максимальное значение. А именно, пусть $\mathbf{J}$ — вектор номеров столбцов, элементы которого зависят от i , и для любого i выполнено $c_{iJ(i)} = 1$.

Для любой i -й функции матрицы $\mathbf{V}$ можно рассмотреть множества значений $v_i(x_1), v_i(x_2), \dots, v_i(x_{J(i)+k})$, где $k = 1, 2, \dots, n - J(i)$. Отметим, что для каждого i известна функция $u_i(x_1, x_2, \dots, x_{J(i)+k}, \mathbf{s}_{ik})$, которая приближает $v_i(x_1, x_2, \dots, x_{J(i)+k})$ с заданной точностью. Здесь $\mathbf{s}_{ik}$ — это конечномерный вектор параметров аппроксимации i -й функции, $k = 1, 2, \dots, n - J(i)$. Вектор параметров $\mathbf{s}_{ik}$ позволяет восстановить значения $u_i(x_1, x_2, \dots, x_{J(i)+k}, \mathbf{s}_{ik})$ на сетку $x_1, x_2, \dots, x_n$. Таким образом, для каждого i можно сформировать матрицу значений функции приближения

$$\mathbf{U}_i = \begin{pmatrix} u_i(x_1, \mathbf{s}_{i1}) & u_i(x_2, \mathbf{s}_{i1}) & \dots & u_i(x_n, \mathbf{s}_{i1}) \\ u_i(x_1, \mathbf{s}_{i2}) & u_i(x_2, \mathbf{s}_{i2}) & \dots & u_i(x_n, \mathbf{s}_{i2}) \\ \dots & \dots & \dots & \dots \\ u_i(x_1, \mathbf{s}_{i(n-J(i))}) & u_i(x_2, \mathbf{s}_{i(n-J(i))}) & \dots & u_i(x_n, \mathbf{s}_{i(n-J(i))}) \end{pmatrix}. \quad (4)$$

Для любого i получаем вектор мер близости функций v_i и u_i на $[a, b]$

$$\mathbf{p}_i = \begin{pmatrix} p_{i[a,b]}(v_i(\mathbf{x}), u_i(\mathbf{x}, \mathbf{s}_{i1})) \\ p_{i[a,b]}(v_i(\mathbf{x}), u_i(\mathbf{x}, \mathbf{s}_{i2})) \\ \dots \\ p_{i[a,b]}(v_i(\mathbf{x}), u_i(\mathbf{x}, \mathbf{s}_{i(n-J(i))})) \end{pmatrix}. \quad (5)$$

Формулу мер близости функций можно представить записью

$$p_{i[a,b]}(v_i(\mathbf{x}), u_i(\mathbf{x}, \mathbf{s}_{ik})) = \frac{1}{n} \sum_{j=1}^n \left| 1 - \frac{|u_i(x_j, \mathbf{s}_{ik})|}{|v_i(x_j)|} \right|. \quad (6)$$

Обозначим через $J' = \max_{i=1,2,\dots,m} (n - J(i))$ максимальную размерность векторов $\mathbf{p}_i$. Далее рассмотрим агрегацию m векторов мер близости (5) в один вектор, например:

$$\bar{p}_j = \frac{1}{m} \sum_{i=1}^m p_{i,j} \quad (p_{i,j} = 0, \text{ если } j > J'),$$

где $j = 1, 2, \dots, J'$, (7)

или

$$\bar{p}_j = \max_{i=1,2,\dots,m} p_{i,j} \quad (p_{i,j} = 0, \text{ если } j > J'),$$

где $j = 1, 2, \dots, J'$. (8)

Обозначим через j' минимальный номер вектора $\bar{\mathbf{p}}$, при котором выполнено $\bar{p}_{j'} \leq \varepsilon_1$. Здесь j' обозначает минимальное количество точек, на которое нужно отступить вправо от максимального значения функций, чтобы получить


приемлемую погрешность экстраполяции. Зная j' , на основе элементов матрицы $\mathbf{C}$ сформируем вектор

$$\bar{\mathbf{c}} = \begin{pmatrix} c_{1(J(1)+j')} \\ c_{2(J(2)+j')} \\ \dots \\ c_{m(J(m)+j')} \end{pmatrix}. \quad (9)$$

Усреднив элементы вектора $\bar{\mathbf{c}}$, получим оптимальный параметр формирования правых границ отрезков эффективного прогнозирования c_r^* . Аналогичным образом определяется c_l^* — оптимальный параметр формирования левых границ отрезков эффективного прогнозирования. Параметры c_l^*, c_r^* могут использоваться для формирования минимальных отрезков эффективного прогнозирования.

Отдельно стоит отметить, что реальные данные часто содержат шумы или ошибки измерений, что требует дополнительной обработки. Для решения этих вопросов применялись стандартные способы.

В исследовании был использован набор данных, описывающий результаты измерения напряжения МТЭ, из работы [16]. В качестве проб для МТЭ применялись два типа сточных вод с различным содержанием органических веществ: бытовые и от пивоваренных заводов. Три МТЭ, обозначенные «А», «В», «С», работали параллельно. Во время проведения измерений напряжение регистрировалось каждые 5 мин до тех пор, пока значения напряжения не достигали 0,02 В (рис. 1, а и б).



■ **Рис. 1.** Примеры изменения напряжения: а — бытовые сточные воды; б — сточные воды пивоваренных заводов
 ■ **Fig. 1.** Examples of voltage changes: а — domestic wastewater; б — wastewater from breweries

Набор данных был представлен 54 экспериментами измерения напряжения. Каждая функция напряжения имела разную длину. Самый долгий эксперимент длился примерно 4,5 сут, что соответствовало 1299 дискретным точкам напряжения. Для выравнивания размерности всех рядов напряжения недостающие значения были заполнены значением 0,02. Таким образом, набор данных с функциями напряжения был представлен матрицей V размерностью 54×1299 с элементами $v_i(x_j) \geq 0$, где $i = 1, 2, \dots, 54; j = 1, 2, \dots, 1299$. Бытовым сточным водам соответствовало 24 функции напряжения, а сточным водам пивоваренной фабрики — 30 функций.

Модель аппроксимации и прогнозирования

Биосенсоры на основе МТЭ перспективны для мониторинга качества воды, но компьютерное моделирование их данных затруднено из-за множества взаимосвязанных параметров. Можно применять ИНС для прогнозирования напряжения, плотности мощности и химических показателей [17, 20], однако такие модели не обладают достаточной интерпретируемостью. В данном исследовании предложен способ, близкий к суррогатному моделированию, где напряжение МТЭ аппроксимируется функцией плотности вероятности логнормального распределения с некоторыми дополнительными слагаемыми. Это упрощает моделирование и сохраняет интерпретируемость результатов.

Исследования показывают, что для некоторых проб воды функция напряжения МТЭ имеет симметричные логнормальные профили с выраженным пиком [21]. Логнормальное распределение широко используется в экологии, например для моделирования содержания загрязняющих веществ, металлов в биотканях, а также для описания геохимических процессов и динамики микроорганизмов в воде [22–25].

Функции напряжения МТЭ отвечают некоторым условиям для применения логнормального распределения. Также для лучшего соответствия экспериментальным данным были рассмотрены варианты добавления нелинейных функций $f(x, s)$ с конечным набором параметров s :

$$u(x, \sigma, \mu, f) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}} + f(x, s). \quad (10)$$

В исследовании проверялись различные варианты добавочных функций. Лучшие результаты экстраполяции напряжения были достигнуты при использовании

$$f(x, \lambda, \delta) = -\frac{\lambda}{\delta + x^2}. \quad (11)$$

Для подбора параметров функции (10) использовалась библиотека SciPy (Python), модуль `optimize.curve_fit`, предлагающий три метода нелинейной оптимизации: метод доверительной области отражения (Trust Region Reflective) [26], алгоритм изгиба с прямоугольными областями доверия и алгоритм Левенберга — Марквардта. Все три метода показали схожую точность аппроксимации, но метод Trust Region Reflective оказался предпочтительным для экстраполяции благодаря возможности задания ограничений на параметры функции. Этот метод является эффективным инструментом для решения задач нелинейной минимизации с ограничениями [27, 28].


Применение метода определения минимальных отрезков эффективного прогнозирования

Предложенный метод был применен к 54 временным рядам напряжения МТЭ, включающим 24 ряда для бытовых сточных вод (первый подкласс) и 30 рядов для сточных вод пивоваренной фабрики (второй подкласс). Для каждого подкласса определялись свои параметры формирования границ отрезков эффективного прогнозирования. Использовалась кросс-валидация по пяти блокам отдельно для функций каждого подкласса. Вектор $x = (a = 0,003472, 0,006944, \dots, 4,510417 = b)$ задавал временную сетку измерений с шагом $h = 0,003472$ сут, что обеспечило удобное масштабирование данных. До подбора параметров функции (10) ряды напряжения были нормализованы по следующей формуле:

$$v_i(x_j)_{norm} = \frac{v_i(x_j) - 0,02}{\max_{j=1,2,\dots,1299} (v_i(x_j)) - 0,02}, \quad j = 1, 2, \dots, 1299; i = 1, \dots, 54. \quad (12)$$

В данном случае 0,02 В — значение окончания большинства экспериментов. Применение нормализации по формуле (12) позволило устранить чувствительность метода к начальным величинам параметров и улучшить сходимость метода.

Начальные параметры для функции прогнозирования определялись в результате вычислительных экспериментов. Для первого подкласса были установлены параметры: $\sigma = 1,5$; $\mu = 0,5$; $\lambda = -0,1$; $\delta = 1$; для второго подкласса: $\sigma = 1,5$; $\mu = 0,5$; $\lambda = 0,1$; $\delta = 0,5$. На параметры были введены дополнительные ограничения, позволяющие более точно определить область поиска



■ **Рис. 2.** Средние значения меры близости функций в зависимости от изменения параметра c при формировании правых границ отрезков: a — первый подкласс; b — второй подкласс

■ **Fig. 2.** The average values of the function proximity measure depending on the change in parameter c when forming the boundaries of segments: a — first subclass; b — second subclass

оптимального решения: для первого подкласса: $0 \leq \sigma \leq 4$; $-0,3 \leq \mu \leq 3,5$; $-1 \leq \lambda \leq 0,3$; $0,8 \leq \delta \leq 1,2$; для второго подкласса: $0 \leq \sigma \leq 1,9$; $-1,5 \leq \mu \leq 0,55$; $-1,5 \leq \lambda \leq 0,15$; $0,05 \leq \delta \leq 1,2$.

Для формирования матрицы C был использован фиксированный набор значений параметра c , определяющего отношения к максимумам функций: (0,95, 0,9, 0,8, 0,75, 0,7, 0,6, 0,55, 0,5, 0,4). Затем были заданы пороговые значения ε_1 для мер близости, агрегированных по формулам (7) и (8). На рис. 2, a и b показаны изменения значений мер близости r , агрегированных по формуле (7), по каждому блоку при изменении значений параметра c .

В результате были определены следующие значения параметров формирования границ отрезков: $c_l^* = 0,95$, $c_r^* = 0,55$ для первого подкласса; $c_l^* = 0,9$, $c_r^* = 0,7$ для второго подкласса. На основе данных параметров были определены минимальные отрезки эффективного прогнозирования.

Анализ результатов экстраполяции и оценка БПК₅

Полученные правые границы отрезков эффективного прогнозирования в среднем соответствовали 13,05 ч для функций первого подкласса и 12,31 ч для функций второго подкласса. На полученных отрезках для каждой функции напряжения был определен набор параметров функции (10). Время завершения прогноза определено экспериментально, так как оно зависит от

особенностей предметной области. Среднее значение используемой меры близости для первого подкласса составило 0,1038 и 0,1272 для второго подкласса. Примеры полученных результатов экстраполяции для некоторых функций приведены на рис. 3, a и b .

По прогнозным значениям напряжения были рассчитаны значения БПК₅ по формулам, полученным в работе [16], т. е. для каждого $i = 1, \dots, 54$ было получено $\bar{b}_i$ — рассчитанное значение БПК₅ в i -м эксперименте. После расчета предсказанные значения БПК₅ сравнивались с реальными значениями, измеренными стандартным пятидневным способом. В качестве метрик были использованы средняя абсолютная

$$MAE = \frac{1}{m} \sum_{i=1}^m |b_i - \bar{b}_i|, \quad (13)$$


максимальная абсолютная

$$MAX = \max_{i=1, \dots, m} |b_i - \bar{b}_i| \quad (14)$$

и средняя относительная ошибки

$$MAPE = \frac{1}{m} \sum_{i=1}^m \frac{|b_i - \bar{b}_i|}{|b_i|} \cdot 100\%. \quad (15)$$

Здесь $\mathbf{b} = (b_1, b_2, \dots, b_{54})$ — это значения БПК₅, измеренные стандартным пятидневным способом и которые также были представлены в наборе данных. Полученные по формулам (13)–(15) оценки приведены в таблице.



■ **Рис. 3.** Примеры результатов аппроксимации и экстраполяции рядов напряжения: *a* — первый подкласс; *б* — второй подкласс

■ **Fig. 3.** Examples of the results of approximation and extrapolation of voltage series: *a* — first subclass; *б* — second subclass

- Оценка прогнозирования БПК₅
- Estimation of BOD₅ prediction

Подкласс	Среднее время, ч	MAE, мг	MAX, мг	MAPE, %
Подкласс 1	13,05	1,17	2,96	8,72
Подкласс 2	12,31	1,13	4,13	7,47
Среднее	12,68	1,15	3,54	8,1

Таким образом, комбинация данных МТЭ с представленной моделью прогнозирования и методом определения минимальных отрезков эффективного прогнозирования позволила сократить время измерения БПК₅ с пяти суток до 12,68 ч с относительной погрешностью 8,1 %, в то время как ИНС из работы [17] давала погрешность 8,42 % для фиксированного входного отрезка, соответствующего 16 ч измерений.

Специалисты и исследователи в области эксплуатации очистных сооружений указывают, что в зависимости от концентрации органических веществ в сточной воде погрешность применяемых методов контроля БПК₅ составляет 13–26 %. При этом отмечается, что применение МТЭ для раннего определения БПК₅ хотя и вносит дополнительную погрешность к погрешности стандартных методов контроля, считается допустимым, если погрешность МТЭ в среднем не превышает 10 % [16]. Представленные в данном исследовании погрешности моделей для прогнозирования БПК₅ приведены с учетом погрешности работы МТЭ. Таким образом, результаты определения

БПК₅ с помощью представленных моделей считались приемлемыми, если полученная средняя относительная ошибка была в пределах 10 %. При этом отметим, что разработанный метод позволяет предсказывать концентрацию БПК₅ с заранее заданной погрешностью. Конечно, сокращение времени измерений может повысить суммарную относительную ошибку определения содержания БПК₅, но метод предоставляет возможность контролировать ее величину. Таким образом обеспечивается возможность нахождения «золотой середины» между точностью контроля сточных вод и временем проведения измерений.

Следует отметить, что математические зависимости между БПК₅ и функциями напряжения справедливы только для стационарных процессов, при которых состав сточных вод и технологические параметры остаются относительно постоянными. Значительные изменения в технологии производства, составе сточных вод или методах их очистки могут привести к изменению функциональных зависимостей между БПК₅ и напряжением. Это требует уточнения или пересмотра зависимостей на основе новых экспериментальных данных. Таким образом, практическое применение разработанных методов справедливо только в рамках данных ограничений.

Синтез данных и применение искусственной нейронной сети

Предложенная выше модель прогнозирования может не учитывать некоторые особенно-

сти поведения рядов напряжения МТЭ. Опыт последних лет показывает, что для разрешения данной ситуации можно попытаться применить ИНС. Но в данном случае значимой трудностью является небольшой объем данных. В последние годы активно развиваются методы оптимизации ИНС для работы с малыми объемами данных, что позволяет повысить их эффективность даже в условиях ограниченных обучающих выборок [29]. И одним из используемых способов является генерация синтетических данных. Последние могут обеспечить количественную и пространственную сбалансированность данных, а также лишены ошибок, которые характерны для экспериментальных данных.

Некоторые комбинации предложенной модели прогнозирования могут использоваться для генерации данных, пригодных для обучения ИНС. Синтезация основана на параметрах функции (10), где добавочная функция имеет вид

$$f(x, \mu_1, \sigma_1, \lambda, \delta) = \frac{\lambda e^{-\frac{(x-\mu_1)^2}{2\sigma_1^2}}}{\sigma_1 \sqrt{2\pi}} + \delta. \quad (16)$$

Функция (10) с добавлением функции (16) обеспечивает высокую точность аппроксимации экспериментальных данных, но неэффективна для экстраполяции на основе коротких начальных отрезков.

В процессе синтеза использовался метод варьирования параметров модели, полученных при аппроксимации экспериментальных функций. Часть результатов предложенного метода синтеза данных была анонсирована нами в тезисах [30]. Для 80 % функций из каждого подкласса были получены параметры аппроксимации ($\sigma, \mu, \lambda, \mu_1, \sigma_1, \delta$). Для каждого параметра рассчитывались стандартные отклонения внутри подклассов. Создание отклонений параметров проводилось с использованием нормального распределения: $\varepsilon_2 \sim N(0, \beta \cdot \text{std})$, где β — коэффициент, задающий масштаб отклонений; **std** — вектор стандартных отклонений каждого параметра. Сгенерированные наборы были получены следующим образом: $(\sigma, \mu, \lambda, \mu_1, \sigma_1, \delta)' = (\sigma, \mu, \lambda, \mu_1, \sigma_1, \delta) + \varepsilon_2$. Всего было синтезировано 2197 наборов параметров, по которым восстанавливались функции напряжения длиной 1299, представленные матрицей V_{gen} размерностью 2197×1299 . Примем данный набор функций за эталон, который должна научиться предсказывать ИНС. Чтобы не обучать несколько ИНС для разных входных временных отрезков, предлагается использовать в качестве входных данных значения функций на отрезках эффективного прогнозирования. При этом, чтобы входные данные имели одинаковую размерность, предлагается приме-

нить функцию прогнозирования (10) с добавочной (11). Это позволит экстраполировать данные до нужной длины 1299 точек на основе отрезков эффективного прогнозирования.

Таким образом, с помощью полученных ранее значений c_l^*, c_r^* для функций матрицы V_{gen} были определены минимальные отрезки эффективного прогнозирования. На данных отрезках были получены параметры модели прогнозирования [комбинация функций (10) и (11)] и на основе данных параметров были восстановлены значения функций приближения длиной 1299. То есть значения приближения и экстраполяции синтезированных функций были представлены матрицей U_{gen} размерностью 2197×1299 . Функции, хранящиеся в матрицах V_{gen} и U_{gen} , являлись обучающей выборкой для ИНС. С помощью ИНС предлагается предсказывать функции матрицы V_{gen} (выходные значения сети) на основе функций матрицы U_{gen} (входные значения). Реальные значения функций напряжения не использовались в обучении, и все 54 функции были использованы в тестовой выборке.

Искусственная нейронная сеть была создана и обучена с использованием библиотеки Keras языка Python, в качестве метода обучения использован Adam со скоростью обучения 0,001. Для снижения вычислительной сложности данные усреднялись за каждые четыре значения, в результате размерность функций сократилась до 325. Матрицы V_{gen} и U_{gen} приняли размерность 2197×325 , где 325 — количество нейронов во входном и выходном слоях сети. В отличие от анонсированных в тезисах [30] результатов применения синтезированных данных для обучения ИНС, в данном исследовании при формировании входных данных был применен разработанный метод поиска минимальных отрезков эффективного прогнозирования. Использовалась трехслойная архитектура ИНС, включающая еще и слой прореживания (20 %) между вторым и третьим слоями. Предварительно каждая функция была нормализована в диапазон от 0 до 1.

Тестирование ИНС проведено на выборке из 54 экспериментальных функций напряжения. По предсказанным функциям напряжения рассчитаны значения БПК₅. Средняя погрешность определения значений БПК₅ составила 8,44 % при среднем времени измерения 12,8 ч. При этом ИНС из работы [17] давала погрешность 10,66 % при использовании фиксированного входного времени 12 ч для всех функций. Для первого подкласса данных относительная погрешность выявления БПК₅ составила 7,39 %, а для второго подкласса 9,28 %. То есть удалось добиться улучшения для функций первого подкласса относительно использования предложенной модели прогнозирования. В частности, ИНС смог-

ла улавливать вторые скачки и широкие пики функций напряжения, чего не могла учитывать предложенная модель прогнозирования (10). За счет увеличения объема обучающих данных снизилась дисперсия ИНС и ее чувствительность к смене параметров. Кроме того, за счет определения минимальных отрезков эффективного прогнозирования отпала необходимость обучать несколько ИНС для разного входного времени.

Заключение

В исследовании разработан метод определения минимальных отрезков эффективного прогнозирования. Метод выявляет ключевые соотношения к максимальным значениям рядов на обучающей выборке, которые в дальнейшем применяются для определения границ отрезков эффективного прогнозирования на схожих рядах. Таким образом, метод определяет параметры формирования таких отрезков с учетом динамики изменений рядов. При этом отсутствует необходимость перебора фиксированных длин отрезков.

Применение метода продемонстрировало эффективность анализа временных рядов напряжения МТЭ, что важно для ранней оценки загрязнения вод. Сочетание метода с предложенной моделью прогнозирования позволило сократить время определения БПК₅ с пяти суток до 12,68 ч с приемлемой погрешностью 8,1 %, что

открывает новые возможности для мониторинга качества сточных вод и управления процессами очистки. Метод ориентирован на однопиковые процессы (например, логнормальные), что ограничивает его применение для более сложных данных. Однако рассмотренные процессы часто встречаются в реальных задачах [21–25]. В дальнейшем может быть рассмотрен вопрос применения предложенного метода там, где временные ряды схожего вида играют ключевую роль.

Также был разработан метод формирования синтетических данных на основе параметров математической модели прогнозирования, который позволил расширить обучающую выборку и повысить эффективность обучения ИНС.

В дополнение отметим, что результаты исследования предоставляют еще один, достаточно качественный, инструмент, который, в том числе, можно использовать для автоматизации процессов обработки временных рядов. Последнее открывает перспективы для их практического применения в различных областях, включая экологию, где точный и быстрый анализ данных может способствовать эффективному мониторингу состояния окружающей среды.

Финансовая поддержка

Исследование выполнено за счет гранта Российского научного фонда (проект № 25-21-00330, <https://rscf.ru/project/25-21-00330/>).

Литература

1. Павлов В. А., Шаповалов В. И., Шестаков Д. С., Кочин А. В., Рудаков А. В., Шабалин А. Е. Сокращение продолжительности наблюдения за кинетикой нагревания подложки при магнетронном распылении медной мишени. *Известия СПбГЭТУ «ЛЭТИ»*, 2021, № 1, с. 12–17. EDN: EXFHQD
2. Полников В. Г., Гоморев И. А. Об оценке режимных значений временных рядов модуля волнения ветра и высоты ветрового волнения. *Метеорология и гидрология*, 2015, № 12, с. 64–73.
3. Полников В. Г., Гоморев И. А. Новый метод оценки режимных значений временных рядов геофизических величин. *Процессы в геосредах*, 2015, № 1, с. 54–60. EDN: VCHUIV
4. Liu S., Yamada M., Collier N., Sugiyama M. Change-point detection in time-series data by relative density-ratio estimation. *Neural Networks*, 2013, vol. 43, pp. 72–83. doi:10.1016/j.neunet.2013.01.012
5. Ruusunen O., Jalli M., Jauhiainen L., Ruusunen M., Leiviskä K. Identification of optimal starting time instance to forecast net blotch density in spring barley with meteorological data in Finland. *Agriculture*, 2022, vol. 12, no. 11, p. 1939. doi:10.3390/agriculture12111939
6. Kawahara Y., Yairi T., Machida K. Change-point detection in time-series data based on subspace identification. *Seventh IEEE International Conference on Data Mining (ICDM 2007)*, 2007, pp. 559–564. doi:10.1109/ICDM.2007.78
7. Kawahara Y., Sugiyama M. Sequential change-point detection based on direct density-ratio estimation. *Statistical Analysis and Data Mining*, 2011, vol. 5, no. 2, pp. 114–127. doi:10.1002/sam.10124
8. Zheng Y., Liu L., Wang L., Xie X. Learning transportation mode from raw gps data for geographic applications on the web. *Proceedings of the 17th International Conference on World Wide Web*, 2008, pp. 247–256. doi:10.1145/1367497.1367532
9. Zhong Y., Ren Y., Cao G., Li F., Qi H. Optimal starting point for time series forecasting. *Expert Systems with Applications*, 2025, vol. 273, p. 126798. doi:10.1016/j.eswa.2025.126798
10. Лебедев И. С. Адаптивное применение моделей машинного обучения на отдельных сегментах выборки в задачах регрессии и классификации. *Информационно-управляющие системы*, 2022,

- № 3, с. 20–30. doi:10.31799/1684-8853-2022-3-20-30
11. Парфёнов И. В., Поляков А. Н. Развитие методики сокращения времени натуральных тепловых испытаний станков. *Интеллект. Инновации. Инвестиции*, 2017, № 2, с. 64–69. EDN: YNLKDD
 12. Поляков А. Н., Кравцов А. Г. Автоматизированная система прогнозирования тепловых характеристик станка. *Вестник Курганского государственного университета. Серия: Технические науки*, 2005, № 2 (2), с. 81–86. EDN: NUIBVB
 13. Li Z., Andreev A., Hramov A., Blyuss O., Zaikin A. Novel efficient reservoir computing methodologies for regular and irregular time series classification. *Nonlinear Dynamics*, 2025, vol. 113, no. 5, pp. 4045–4062. doi:10.1007/s11071-024-10244-3
 14. Курбако А. В., Кульминский Д. Д., Боровкова Е. И., Киселев А. Р., Сказкина В. В., Пономаренко В. И., Прохоров М. Д., Безручко Б. П., Гриднев В. И., Караваев А. С. Повышение чувствительности метода диагностики в реальном времени фазовой синхронизации автогенераторов по их нестационарным временным рядам. *Известия вузов. Прикладная нелинейная динамика*, 2021, т. 29, № 6, с. 892–904. doi:10.18500/0869-6632-2021-29-6-892-904
 15. Nagel B., Dellweg H., Gierasch L. M. Glossary for chemists of terms used in biotechnology (IUPAC Recommendations 1992). *Pure and Applied Chemistry*, 1992, vol. 64, no. 1, pp. 143–168. doi:10.1351/pac199264010143
 16. Tardy G. M., Lóránt B., Gyalai-Korpos M., Bakos V., Simpson D., Goryanin I. Microbial fuel cell biosensor for the determination of biochemical oxygen demand of wastewater samples containing readily and slowly biodegradable organics. *Biotechnology Letters*, 2021, vol. 43, no. 2, pp. 445–454. doi:10.1007/s10529-020-03050-5
 17. Medvedev I., Kornaukhova M., Galazis C., Lóránt B., Tardy G. M., Losev A., Goryanin I. Using AI and BES/MFC to decrease the prediction time of BOD5 measurement. *Environmental Monitoring and Assessment*, 2023, vol. 195, no. 9, p. 1018. doi:10.1007/s10661-023-11576-0
 18. Lóránt B., Gyalai-Korpos M., Goryanin I., Tardy G. M. Single chamber air–cathode microbial fuel cells as biosensors for determination of biodegradable organics. *Biotechnology Letters*, 2019, vol. 41, no. 4, pp. 555–563. doi:10.1007/s10529-019-02668-4
 19. Wang Y., Liu X., Wang M., Zhang P., Zong Y., Zhang Q. A single-chamber microbial fuel cell for rapid determination of biochemical oxygen demand using low-cost activated carbon as cathode catalyst. *Environmental Technology*, 2018 vol. 39, no. 24, pp. 3228–3237. doi:10.1080/09593330.2017.1375998
 20. Oyediji M. O., Alharbi A., Aldhaifallah M., Rezk H. Optimal data-driven modelling of a microbial fuel cell. *Energies*, 2023, vol. 16, no. 12, p. 4740. doi:10.3390/en16124740
 21. Feng Y., Barr W., Harper Jr W. F. Neural network processing of microbial fuel cell signals for the identification of chemicals present in water. *Journal of Environmental Management*, 2013, vol. 120, pp. 84–92. doi:10.1016/j.jenvman.2013.01.018
 22. Andersson A. Mechanisms for log normal concentration distributions in the environment. *Scientific Reports*, 2021, vol. 11, no. 1, p. 16418. doi:10.1038/s41598-021-96010-6
 23. Ott W. R. A physical explanation of the lognormality of pollutant concentrations. *Journal of the Air & Waste Management Association*, 1990, vol. 40, no. 10, pp. 1378–1383. doi:10.1080/10473289.1990.10466789
 24. Долгонос Б. М., Корчагин К. А., Мессинева Е. М. Модель флуктуаций бактериологических показателей качества речной воды. *Водные ресурсы*, 2006, т. 33, № 6, с. 686–700. EDN: HYVAWF
 25. Савичев О. Г., Луен Н. В. О методике определения фоновых и аномальных значений гидрогеохимических показателей. *Известия Томского политехнического университета. Инжиниринг георесурсов*, 2015, т. 326, № 9, с. 133–142. EDN: UZCCDH
 26. Coleman T. F., Li Y. An interior trust region approach for nonlinear minimization subject to bounds. *SIAM Journal on Optimization*, 1996, vol. 6, no. 2, pp. 418–445. doi:10.1137/0806023
 27. Gao X., Hou Q., Yao S., Zhou K. Opposite Normalized Trust-Region Reflective (ONTRR): A new algorithm for parameter extraction of single, double and triple diode solar cell models. *Applied Sciences*, 2023, vol. 13, no. 14, p. 8199. doi:10.3390/app13148199
 28. Le T. M., Fatahi B., Khabbaz H., Sun W. Numerical optimization applying trust-region reflective least squares algorithm with constraints to optimize the non-linear creep parameters of soft soil. *Applied Mathematical Modelling*, 2017, vol. 41, pp. 236–256. doi:10.1016/j.apm.2016.08.034
 29. Гейдаров П. Ш. Исследование устойчивости многослойного персептрона с вычисляемыми весами синапсов к меньшим объемам обучающей выборки. *Информационно-управляющие системы*, 2023, № 2, с. 2–14. doi:10.31799/1684-8853-2023-2-2-14, EDN: WOHNME
 30. Медведев И. А., Корнаухова М. А. Комбинация нейронной сети и математической модели прогнозирования напряжения микробных топливных элементов. *Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сборник статей по материалам Девятой всероссийской научно-практической конференции с международным участием*, Пермь, 17–18 октября 2024 г. Пермь, Пермский государственный национальный исследовательский университет, 2024, с. 238–242. EDN: KLOGSC

UDC 519.246.8

doi:10.31799/1684-8853-2025-3-2-13

EDN: RAJEBP

Method of minimizing the duration of observations and mathematical extrapolation models at small data volumesA. G. Losev^a, Dr. Sc., Phys.-Math., Professor, orcid.org/0000-0002-1072-8375, alexander.losev@volsu.ruI. A. Medvedev^a, Post-Graduate Student, orcid.org/0009-0001-2536-4359^aVolgograd State University 100, Universitetsky Ave., 400062, Volgograd, Russian Federation

Introduction: Extrapolation of time series values with small amount of data is a topical problem, especially in areas where fast decision making based on limited information is required. One of the key problems is to find the smallest interval of historical data sufficient to make an accurate forecast of subsequent values of a time series. **Purpose:** To develop a method for minimizing time observations that allows extrapolation of future values with a predetermined accuracy, and to develop a data synthesis method based on the parameters of the mathematical forecasting model. **Results:** First, we develop a method for determining the minimum segments of effective forecasting. The method assumes the presence of a training sample and is based on the analysis of the dynamics of changes in the values of time series around its maximum, which makes it possible to automatically determine the minimum data segments required to make predictions with a predetermined accuracy. Second, we develop a method for generating synthetic data using the variation of the parameters of the mathematical model. Data synthesis based on varying the parameters of the mathematical model of forecasting makes it possible to increase the efficiency of training artificial neural networks. The developed methods have been applied in the analysis of microbial fuel cell voltage time series to estimate the parameter of wastewater pollution – biochemical oxygen demand. As a result, it has been possible to reduce the prediction time of this parameter from 5 days to 12.68 hours with a relative error of 8.1 %. **Practical relevance:** The developed methods used during environmental monitoring open the possibility to promptly assess water pollution and optimize wastewater treatment processes.

Keywords – mathematical extrapolation models, data synthesis, time series, artificial neural network, lognormal distribution, microbial fuel cell, biochemical oxygen demand.

For citation: Losev A. G., Medvedev I. A. Method of minimizing the duration of observations and mathematical extrapolation models at small data volumes. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 2–13 (In Russian). doi:10.31799/1684-8853-2025-3-2-13, EDN: RAJEBP

Financial support

The study was supported by the Russian Science Foundation (project No. 25-21-00330, <https://rscf.ru/project/25-21-00330/>).

References

- Pavlov V. A., Shapovalov V. I., Shestakov D. S., Kochyn A. V., Rudakov A. V., Shabalin A. E. Shortening the duration of observation of the substrate heating kinetics using magnetron sputtering of a copper target. *Izvestiya SPbGETU "LETI"*, 2021, no. 1, pp. 12–17 (In Russian). EDN: EXFHQD
- Polnikov V. G., Gomorev I. A. On estimating the return values for time series of wind speed and wind wave height. *Russian Meteorology and Hydrology*, 2015, vol. 40, no. 12, pp. 820–827. doi:10.3103/S1068373915120079
- Polnikov V. G., Gomorev I. A. A new method of estimating return values for time series of geophysical magnitudes. *Process in Geomedia*, 2015, no. 1, pp. 54–60 (In Russian). EDN: VCHUIV
- Liu S., Yamada M., Collier N., Sugiyama M. Change-point detection in time-series data by relative density-ratio estimation. *Neural Networks*, 2013, vol. 43, pp. 72–83. doi:10.1016/j.neunet.2013.01.012
- Ruusunen O., Jalli M., Jauhiainen L., Ruusunen M., Leiviskä K. Identification of optimal starting time instance to forecast net blotch density in spring barley with meteorological data in Finland. *Agriculture*, 2022, vol. 12, no. 11, p. 1939. doi:10.3390/agriculture12111939
- Kawahara Y., Yairi T., Machida K. Change-point detection in time-series data based on subspace identification. *Seventh IEEE International Conference on Data Mining (ICDM 2007)*, 2007, pp. 559–564. doi:10.1109/ICDM.2007.78
- Kawahara Y., Sugiyama M. Sequential change-point detection based on direct density-ratio estimation. *Statistical Analysis and Data Mining*, 2011, vol. 5, no. 2, pp. 114–127. doi:10.1002/sam.10124
- Zheng Y., Liu L., Wang L., Xie X. Learning transportation mode from raw gps data for geographic applications on the web. *Proceedings of the 17th International Conference on World Wide Web*, 2008, pp. 247–256. doi:10.1145/1367497.1367532
- Zhong Y., Ren Y., Cao G., Li F., Qi H. Optimal starting point for time series forecasting. *Expert Systems with Applications*, 2025, vol. 273, p. 126798. doi:10.1016/j.eswa.2025.126798
- Lebedev I. S. Adaptive application of machine learning models on separate segments of a data sample in regression and classification problems. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2022, no. 3, pp. 20–30 (In Russian). doi:10.31799/1684-8853-2022-3-20-30
- Parfenov I. V., Polyakov A. N. Development of technique for reducing the time of machines full-scale thermal testings. *Intellect. Innovations. Investments*, 2017, no. 2, pp. 64–69 (In Russian). EDN: YNLKDD
- Polyakov A. N., Kravtsov A. G. Automated system for predicting the thermal characteristics of the machine. *Vestnik Kurganskogo gosudarstvennogo universiteta. Seriya: Tekhnicheskie nauki*, 2005, no. 2 (2), pp. 81–86 (In Russian). EDN: NUIBVB
- Li Z., Andreev A., Hramov A., Blyuss O., Zaikin A. Novel efficient reservoir computing methodologies for regular and irregular time series classification. *Nonlinear Dynamics*, 2025, vol. 113, no. 5, pp. 4045–4062. doi:10.1007/s11071-024-12044-3
- Kurbako A. V., Kulminskiy D. D., Borovkova E. I., Kiselev A. R., Skazkina V. V., Ponomarenko V. I., Prokhorov M. D., Bezruchko B. P., Gridnev V. I., Karavaev A. S. Increasing the sensitivity of real-time method for diagnostic of autogenerators phase synchronization based on their non-stationary time series. *Izvestiya VUZ. Applied Nonlinear Dynamics*, 2021, vol. 29, no. 6, pp. 892–904 (In Russian). doi:10.18500/0869-6632-2021-29-6-892-904
- Nagel B., Dellweg H., Gierasch L. M. Glossary for chemists of terms used in biotechnology (IUPAC Recommendations 1992). *Pure and Applied Chemistry*, 1992, vol. 64, no. 1, pp. 143–168. doi:10.1351/pac199264010143
- Tardy G. M., Lóránt B., Gyalai-Korpos M., Bakos V., Simpson D., Goryanin I. Microbial fuel cell biosensor for the determination of biochemical oxygen demand of wastewater samples containing readily and slowly biodegradable organics. *Biotechnology Letters*, 2021, vol. 43, no. 2, pp. 445–454. doi:10.1007/s10529-020-03050-5
- Medvedev I., Kornaukhova M., Galazis C., Lóránt B., Tardy G. M., Losev A., Goryanin I. Using AI and BES/MFC to decrease the prediction time of BOD5 measurement. *Environmental Monitoring and Assessment*, 2023, vol. 195, no. 9, p. 1018. doi:10.1007/s10661-023-11576-0
- Lóránt B., Gyalai-Korpos M., Goryanin I., Tardy G. M. Single chamber air-cathode microbial fuel cells as biosensors for determination of biodegradable organics. *Biotechnology*

- Letters, 2019, vol. 41, no. 4, pp. 555–563. doi:10.1007/s10529-019-02668-4
19. Wang Y., Liu X., Wang M., Zhang P., Zong Y., Zhang Q. A single-chamber microbial fuel cell for rapid determination of biochemical oxygen demand using low-cost activated carbon as cathode catalyst. *Environmental Technology*, 2018, vol. 39, no. 24, pp. 3228–3237. doi:10.1080/09593330.2017.1375998
 20. Oyediji M. O., Alharbi A., Aldhaifallah M., Rezk H. Optimal data-driven modelling of a microbial fuel cell. *Energies*, 2023, vol. 16, no. 12, p. 4740. doi:10.3390/en16124740
 21. Feng Y., Barr W., Harper Jr W. F. Neural network processing of microbial fuel cell signals for the identification of chemicals present in water. *Journal of Environmental Management*, 2013, vol. 120, pp. 84–92. doi:10.1016/j.jenvman.2013.01.018
 22. Andersson A. Mechanisms for log normal concentration distributions in the environment. *Scientific Reports*, 2021, vol. 11, no. 1, p. 16418. doi:10.1038/s41598-021-96010-6
 23. Ott W. R. A physical explanation of the lognormality of pollutant concentrations. *Journal of the Air & Waste Management Association*, 1990, vol. 40, no. 10, pp. 1378–1383. doi:10.1080/10473289.1990.10466789
 24. Dolgonosov B. M., Korchagin K. A., Messineva E. M. Model of fluctuations in bacteriological indices of water quality. *Water Resources*, 2006, vol. 33, no. 6, pp. 637–650. doi:10.1134/S0097807806060054, EDN: LJXQOV
 25. Savichev O. G., Luyen N. V. The technique of determining background and extreme values of hydrogeochemical parameters. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 2015, vol. 326, no. 9, pp. 133–142 (In Russian). EDN: UZCCDH
 26. Coleman T. F., Li Y. An interior trust region approach for nonlinear minimization subject to bounds. *SIAM Journal on Optimization*, 1996, vol. 6, no. 2, pp. 418–445. doi:10.1137/0806023
 27. Gao X., Hou Q., Yao S., Zhou K. Opposite Normalized Trust-Region Reflective (ONTRR): A new algorithm for parameter extraction of single, double and triple diode solar cell models. *Applied Sciences*, 2023, vol. 13, no. 14, p. 8199. doi:10.3390/app13148199
 28. Le T. M., Fatahi B., Khabbaz H., Sun W. Numerical optimization applying trust-region reflective least squares algorithm with constraints to optimize the non-linear creep parameters of soft soil. *Applied Mathematical Modelling*, 2017, vol. 41, pp. 236–256. doi:10.1016/j.apm.2016.08.034
 29. Geidarov P. Sh. Investigating stability of a multilayer perceptron with calculated synaptic weights to smaller training sample sizes. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2023, no. 2, pp. 2–14 (In Russian). doi:10.31799/1684-8853-2023-2-2-14, EDN: WOHNNE
 30. Medvedev I. A., Kornaukhova M. A. Combination of a neural network and a mathematical model for predicting the voltage of microbial fuel cells. *Iskusstvennyy intellekt v reshenii aktual'nykh sotsial'nykh i ekonomicheskikh problem XXI veka: Sbornik statey po materialam Devyatoy vserossiyskoy nauchno-prakticheskoy konferentsii s mezhduнародnym uchastiem* [Artificial Intelligence in Solving Current Social and Economic Problems of the 21st Century: Proceedings of the 9th All-Russian Scientific-Practical Conference with International Participation]. Perm, 2024, pp. 238–242 (In Russian). EDN: KLOGSC

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>



Многоагентный ансамблевый алгоритм акустического распознавания нарушений работоспособности автономного технологического оборудования

Н. А. Верзун^{а,б}, канд. техн. наук, доцент, orcid.org/0000-0002-0126-2358, verzun.n@unecon.ru

М. О. Колбанев^{а,б}, доктор техн. наук, профессор, orcid.org/0000-0003-4825-6972

А. Р. Салиева^а, аспирант, orcid.org/0009-0001-9519-5773

^аСанкт-Петербургский государственный электротехнический университет «ЛЭТИ», Профессора Попова ул., 5, Санкт-Петербург, 197376, РФ

^бСанкт-Петербургский государственный экономический университет, наб. канала Грибоедова, 30-32, Санкт-Петербург, 191023, РФ

Введение: в условиях высокоавтоматизированных производств традиционные методы диагностики функционирования технологического оборудования, основанные на визуальном осмотре или механических датчиках, часто оказываются недостаточными. С учетом автономных режимов работы оборудования, использующего искусственный интеллект, все большее значение приобретают автоматические системы мониторинга с привлечением акустических данных, которые могут сигнализировать о неисправностях без вмешательства в процесс работы. **Цель:** разработать многоагентный ансамблевый алгоритм акустического распознавания, способный выявлять различные типы нарушений в работе автономных технических систем с точностью не менее 90 %, F1-мерой $\geq 0,85$. **Результаты:** предложен новый подход к акустическому распознаванию неисправностей автономного технологического оборудования, основанный на многоагентном ансамблевом алгоритме. Разработана архитектура многоагентной системы, включающая четырех специализированных агентов, анализирующих различные параметры акустических сигналов: 1) агент спектрального анализа оценивает изменения частотного состава акустического сигнала, выявляя аномальные колебания, характерные для механических повреждений и неисправностей; 2) агент временного анализа отслеживает временные паттерны акустических данных, анализируя изменения амплитуды и продолжительности сигналов, что позволяет выявлять кратковременные сбои и нерегулярные шумы; 3) агент анализа функционирования оборудования соотносит акустические данные с рабочими режимами оборудования, выявляя отклонения от нормального функционирования; 4) агент анализа внешнего окружения учитывает внешние шумовые факторы и фильтрует их, повышая точность диагностики путем исключения посторонних звуков. Агенты реализованы и обучены с использованием методов машинного и глубокого обучения. В рамках исследования проведен эксперимент, в котором оценена эффективность предложенного алгоритма. Точность распознавания неисправностей достигала не менее 90 %. Проведенное исследование показало, что применение многоагентного подхода позволяет повысить надежность диагностики за счет объединения результатов работы различных аналитических моделей. **Практическая значимость:** программный код, реализующий ансамблевый алгоритм распознавания, может применяться для диагностики широкого круга автономных систем.

Ключевые слова — акустическое распознавание, автономное технологическое оборудование, ансамблевый алгоритм, эмпирическое разложение по модам.

Для цитирования: Верзун Н. А., Колбанев М. О., Салиева А. Р. Многоагентный ансамблевый алгоритм акустического распознавания нарушений работоспособности автономного технологического оборудования. *Информационно-управляющие системы*, 2025, № 3, с. 14–24. doi:10.31799/1684-8853-2025-3-14-24, EDN: VHOSZZ

For citation: Verzun N. A., Kolbanev M. O., Salieva A. R. Multi-agent ensemble algorithm for acoustic recognition of malfunctions of autonomous technological equipment. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 14–24 (In Russian). doi:10.31799/1684-8853-2025-3-14-24, EDN: VHOSZZ

Введение

Современные автономные системы, такие как беспилотные летательные аппараты, промышленные роботы и оборудование различных видов, играют ключевую роль в производственных процессах [1]. Эффективность и безопасность их применения зависят от своевременного выявления нарушений работоспособности. При этом диагностика, предусматривающая участие людей, зачастую просто невозможна и может быть заменена анализом акустических данных, которые позволяют обнаруживать ранние признаки

неисправностей без физического вмешательства в процесс функционирования систем [2].

В статье [3] показано, что обучение с подкреплением перспективно для применения в логистических системах, которые включают в себя и акустические системы распознавания. В настоящей статье предлагаются и исследуются конкретные технические решения, которые позволят эффективно диагностировать неисправности в логистических системах, а именно, предлагается новый подход к акустическому распознаванию нарушений работоспособности автономно работающего технологического оборудования с ис-

пользованием многоагентного ансамблевого алгоритма на основе обучения с подкреплением, который обеспечивает высокую гибкость, масштабируемость и точность диагностики за счет изучения каждым агентом части характеристик акустических сигналов с последующей агрегацией полученных данных [4].

Структура системы акустического распознавания

Акустический сигнал в общем случае представляет собой смесь сигналов, которые вырабатываются диагностируемым оборудованием и его внешним окружением [5]. Звуковой сигнал, воспроизводимый оборудованием, воспринимается акустическим датчиком. Важно обеспечить точность записи сигнала, ослабить влияние шумов и искажений, сохраняя все ключевые особенности звука, поскольку от этого зависит корректность его анализа в дальнейшем [6]. Система акустического распознавания реализует обработку и классификацию акустических данных на основе ансамблевого алгоритма, объединяющего результаты, полученные от различных агентов. Используется комбинация нескольких специализированных агентов, каждый из которых фокусируется на определенном аспекте акустического сигнала. Для повышения точности и надежности распознавания учитываются:

- спектральные характеристики сигнала: частотный спектр, амплитуда и фаза звуковых волн, гармоники, — которые могут указывать на определенные типы звуков, такие как работающие механизмы или нарушения [7];

- временные паттерны: длительность звуковых событий, их последовательность и интервалы между ними, — что позволяет различать нор-

мальное функционирование оборудования от его отказов [8];

- информация о функционировании оборудования: условия эксплуатации оборудования, например, тип технологического процесса, специфику его работы и возможные источники помех, — что может помочь в более точной интерпретации акустических сигналов [9];

- особенности внешнего окружения: факторы окружающей среды, такие как уровень фонового шума, отражения звука от стен и других объектов, — что может повлиять на качество и точность распознавания звуковых сигналов [10].

Структура системы акустического распознавания показана на рис. 1.

Рассмотрим каждый компонент подробнее.

Предобработка сигнала. Выполняются:


- нормализация амплитуды — уравниваются степени громкости для устранения значительных перепадов амплитуды и улучшения качества обработки;

- удаление шума — применяются фильтры (например, полосовой фильтр) для удаления фоновых шумов и улучшения четкости полезного сигнала;

- сегментация сигнала — длинный сигнал делится на более короткие фрагменты для более точного анализа и локализации звуковых событий;

- извлечение важных характеристик — применяются такие методы, как мел-кепстральные коэффициенты для выделения речевых признаков, и спектрограммы для анализа частотных компонентов сигнала. Это позволяет получить набор признаков, который используется на следующих этапах [11].

Многоагентная система анализа состоит из специализированных агентов. Эти агенты используют методы машинного обучения и глубокого обучения, обученные на соответствующих типах данных [12]:



■ **Рис. 1.** Структура системы акустического распознавания

■ **Fig. 1.** The structure of the acoustic recognition system

— агент спектрального анализа изучает частотные характеристики сигнала, используя методы спектрального анализа и сверточные нейронные сети, специализируется на извлечении частотных особенностей, таких как тональные характеристики звука;

— агент временного анализа исследует временные закономерности сигнала, например паузы, изменение интенсивности, использует рекуррентные нейронные сети для анализа временной динамики, что важно для распознавания последовательных паттернов [13];

— агент анализа функционирования оборудования анализирует более высокоуровневые контекстные признаки сигнала, применяя трансформеры для захвата зависимостей между различными частями сигнала, что полезно для распознавания более сложных акустических событий, например фраз в речевом потоке;

— агент анализа внешнего окружения оценивает шумы, помехи и другие характеристики окружающей среды, чтобы учитывать их влияние на качество сигнала, применяет методы обработки сигналов для работы с низкокачественными или зашумленными данными [14].

Каждый агент использует специфические алгоритмы машинного обучения для анализа соответствующих аспектов сигнала.

Ансамблевый агрегатор принятия решения. Ансамблевая агрегация позволяет объединять результаты, полученные от всех агентов, для формирования общего решения [15]. Подобный подход нацелен на снижение вероятности пропуска критичных признаков нарушений и повышение общей эффективности системы мониторинга [16]. Для организации ансамбля используются:

— взвешенное голосование — каждый агент голосует за свое решение и каждому голосу присваивается вес в зависимости от точности данного агента; этот метод обеспечивает баланс между мнениями агентов с учетом их опыта, а также позволяет учитывать разнородность данных и повышать устойчивость системы к ошибкам;

— ансамблевые методы, основанные на идее объединения результатов нескольких моделей или алгоритмов для получения более точного и надежного результата; основные принципы ансамблевых методов: разнообразие — использование различных типов моделей или алгоритмов, независимость — минимизация корреляции между ошибками отдельных моделей, агрегация — эффективное объединение результатов отдельных моделей [17].

Принятие решений позволяет сделать окончательный вывод о состоянии оборудования. Модуль принимает выходные данные от агентов. Далее проводится нормализация данных для унификации их масштаба. После этого вы-

числяется степень уверенности каждого агента на основе метрики точности, полученной в процессе обучения. Затем осуществляется комбинирование результатов с использованием взвешенного голосования и принимается окончательное решение.

Алгоритм и математическая модель обучения агентов

Обучение агента заключается в выработке правильных решений о состоянии автономно работающего оборудования. При обучении агентов последовательно выполняются следующие шаги.

1. Инициализировать агентов случайными весами.

2. Для каждого обучающего примера:

- выполнить предобработку;
- пропустить через всех агентов;
- агрегировать результаты;
- вычислить ошибку;
- обновить веса агентов и агрегатора.

3. Повторять шаг 2 до сходимости.

Работа агентов в системе построена на базе глубокого обучения с подкреплением. В частности, для задач акустического распознавания звуковых сигналов может использоваться алгоритм глубоких Q-сетей (Deep Q-Network, DQN). Он эффективен для акустического распознавания звуковых сигналов с изменяющимися состояниями [18].

Агенты (см. рис. 1), решая свои задачи, выполняют следующие операции.

1. Выбор действия агентом. DQN эффективно обучает агента принимать решения в сложных средах, что делает его полезным для задач, где требуется многократное взаимодействие с системой, например для акустического распознавания с различными состояниями звуковых сигналов:

$$Q(s, a) \leftarrow Q(s, a) + \alpha(R + \gamma \max_{a'} Q(s', a') - Q(s, a)),$$

где $Q(s, a)$ — текущее значение Q-функции (оценка полезности) для состояния s и действия a ; α — скорость обучения, параметр от 0 до 1, который контролирует, насколько сильно обновляется значение; R — вознаграждение, полученное за выполнение действия a в состоянии s ; γ — коэффициент дисконтирования, отражает важность будущих наград; s' — следующее состояние после выполнения действия a в состоянии s ; $Q(s', a')$ — Q-значение для следующего состояния s' и действия a' ; $\max_{a'} Q(s', a')$ — максимальное значение Q-функции для всех возможных действий a' в следующем состоянии s' . Это оценка наилуч-

шего возможного действия в будущем. $Q(s, a) \leftarrow Q(s, a) \dots$ означает обновление старого значения Q -функции новым, более точным, на основе полученного опыта.

2. Функция потерь для обновления Q -функции. Функция потерь минимизирует разницу между текущими оценками и целевыми значениями, что позволяет агенту улучшать свои решения. Для расчета функции потерь применяется беллмановское уравнение для оптимизации стратегий в задачах с последовательными действиями, таких как управление звуковыми сигналами в реальном времени:

$$L = E \left[\left(R + \gamma \frac{\max_{a'} Q(s', a') - Q(s, a)}{a'} \right) \right],$$

где L — функция потерь; $E[\dots]$ — математическое ожидание. Данная функция минимизирует ошибку между предсказанной и фактической наградой, что позволяет агенту улучшать свои стратегии.

Результаты от отдельных агентов агрегируются в ансамбле, что помогает выбирать верные действия.

Ансамблевое решение. Для повышения устойчивости к шуму и случайным ошибкам отдельных агентов используется ансамблевый подход. Окончательное действие выбирается на основе моды

$$a_{ensemble} = \text{mode}(a_1, a_2, \dots, a_n),$$

где a_i — действие, выбранное i -м агентом, а n — число агентов. Использование моды позволяет учитывать решение большинства агентов, повышая надежность системы в условиях неопределенности.

Для ускорения обучения и повышения кооперации между агентами вводится механизм адаптивного распределения наград:

$$R_i = \begin{cases} R \times (1 + \lambda) \\ R \times (1 + \beta) \end{cases},$$

где R_i — награда i -го агента; R — общая награда; λ и β — коэффициенты усиления и ослабления соответственно (например, $\lambda = 0,1$, $\beta = -0,1$). Этот подход стимулирует агентов достигать консенсуса, а также поощряет решения, способствующие общим целям системы.

Для того чтобы не было заикливания в начале обучения, в нашем ансамбле предлагается использовать ϵ -жадную стратегию исследования. Она позволяет агентам исследовать новые стратегии в начале обучения, чтобы не застрять в локальных оптимумах. На поздних стадиях агенты могут больше полагаться на накоп-

ленные знания, что улучшает их долгосрочную производительность:

$$\epsilon_t = \max(\epsilon_{\min}, \epsilon_0 \times \delta^t),$$

где ϵ_t — значение ϵ на шаге t ; $\epsilon_{\min}$ — минимальное значение ϵ ; ϵ_0 — начальное значение ϵ , а δ^t — коэффициент затухания.

Для того чтобы эффективно отслеживать среднюю награду без необходимости хранить все предыдущие значения, используем инкрементальное обновление среднего значения награды

$$\bar{R}_t = \bar{R}_{t-1} + \frac{1}{t}(R_t - \bar{R}_{t-1}),$$

где $\bar{R}_t$ — среднее значение награды на шаге t , а R_t — награда на шаге t .

Оценка качества распознавания

Тестирование алгоритма проводилось на различных типах оборудования для оценки его эффективности в распознавании аномалий. При этом для оценки качества распознавания использовались метрики [19]:

— точность (Precision) — показывает, какой процент всех предсказанных положительных значений действительно является положительным:

$$P = \frac{TP}{TP + FP} \times 100\%,$$

где TP (True Positives) — количество истинно положительных результатов, т. е. правильное распознавание нарушений; FP (False Positives) — количество ложноположительных результатов, т. е. ошибочное распознавание нарушений. Высокая точность означает, что алгоритм редко ошибается, предсказывая положительные значения;

— полнота (Recall) — показывает, какой процент из всех реальных положительных значений был правильно предсказан как положительные значения:

$$R = \frac{TP}{TP + FN} \times 100\%,$$

где FN (False Negatives) — количество ложноотрицательных результатов, т. е. нераспознанных нарушений. Высокая полнота означает, что алгоритм не пропускает положительные классы;

— F -мера — гармоническое среднее точности и полноты:

$$F = \frac{2PR}{P + R} \times 100\%;$$

— ложные срабатывания (False Positive Rate)

$$FPR = \frac{FP}{TP + FP + TN + FN} \times 100\%,$$

где TN (True Negatives) — количество истинно отрицательных результатов, т. е. правильное отсутствие нарушений.

Описание эксперимента

Цель эксперимента — проверить работоспособность и оценить эффективность многоагентного ансамблевого алгоритма для акустического распознавания нарушений работоспособности автономного технологического оборудования. Проектирование вычислительной системы, обеспечивающей заданное время отклика, в данной статье не рассматривается, что позволило использовать для проведения эксперимента доступную и относительно недорогую вычислительную систему.

Оборудование и материалы:

- компьютер (процессор Intel Core i5-8300H (4 ядра, 2.3–4.0 ГГц), 32 ГБ RAM, SSD-накопитель 1 ТБ) с установленным Python 3.4 и необходимыми библиотеками;
- набор данных MIMII;
- автономное технологическое оборудование для тестирования (опционально).

Специализированные библиотеки для Python:

- TensorFlow и PyTorch для построения и обучения нейронных сетей, включая модели для агентов;
- Stable Baselines3 для реализации алгоритмов обучения с подкреплением (в частности, DQN);
- Ray и RLlib для управления многоагентными системами, позволяют проводить распределенное обучение агентов и масштабируемую обработку данных;
- Librosa для обработки аудиоданных, включая функции анализа акустических сигналов, такие как формирование спектрограммы, извлечение частотных характеристик методом мел-кепстральных коэффициентов.

Исходные данные для обучения агентов.

Для обучения многоагентного ансамблевого алгоритма акустического распознавания неисправностей использовались акустические сигналы из тщательно отобранных открытых баз данных. Эти базы данных обеспечивают разнообразие сценариев и условий функционирования оборудования, что значительно повышает качество и универсальность обученной модели. Использовались следующие датасеты.

1. MIMII Dataset (Malfunctioning Industrial Machine Investigation and Inspection). Этот на-

бор данных является одной из наиболее популярных коллекций для исследований в области диагностики неисправностей промышленного оборудования. Он содержит аудиозаписи работы четырех типов оборудования: насосов, вентиляторов, клапанов и компрессоров. Для каждого типа представлены как записи нормального состояния, так и акустические сигналы, соответствующие различным типам неисправностей. Уникальность набора MIMII заключается в том, что он моделирует реальные производственные условия, включая фоновый шум, что делает его полезным для разработки алгоритмов, устойчивых к внешним акустическим помехам (*MIMII Dataset: Sound Dataset for Malfunctioning Industrial Machine Investigation and Inspection*. <https://zenodo.org/records/3384388>).

2. Industrial Sound Data for Anomalous Sound Detection (DCASE Challenge). Данный набор был специально разработан для задач обнаружения аномалий звуков в промышленной среде в рамках конкурсов серии DCASE. Коллекция охватывает широкий спектр устройств, таких как насосы, двигатели и компрессоры. Отличительной чертой этого набора является его фокус на реальных производственных условиях. Он включает звуки как нормальной работы оборудования, так и редкие, трудноуловимые акустические аномалии, что делает его незаменимым инструментом для повышения чувствительности алгоритмов к незначительным отклонениям в звуках (*Detection and Classification of Acoustic Scenes and Events*. <https://dcase.community/>).

3. ToyADMOS Dataset. Набор ToyADMOS был разработан специально для исследований в области обнаружения аномалий на примере звуков игрушечного промышленного оборудования. Хотя масштабы и физические характеристики таких устройств могут отличаться от крупного промышленного оборудования, их акустические сигналы представляют ценность для разработки алгоритмов. ToyADMOS содержит звуки нормальной и аномальной работы, что позволяет изучать характерные особенности, свойственные разным типам неисправностей, в условиях низкой интенсивности звука и минимального шума (*Dataset from Zenodo* (2020). <https://zenodo.org/records/4580270>).

Анализ результатов эксперимента

Результаты работы многоагентного ансамблевого алгоритма отражены в табл. 1, где приводятся показатели оценки эффективности распознавания неисправностей для различных типов оборудования и нарушений: точность, полнота, F1-мера и уровень ложных срабатываний. Эти метрики дают всестороннее представление о ка-

■ **Таблица 1.** Показатели оценки эффективности распознавания неисправностей для различных типов оборудования и нарушений

■ **Table 1.** Indicators for assessing the effectiveness of fault recognition for various types of equipment and malfunctions

Тип оборудования	Тип нарушения	Точность, %	Полнота, %	F1-мера, %	Ложные срабатывания, %
Насос	Вибрации	94	91	92	5
Насос	Трение	92	90	91	6
Вентилятор	Неравномерный шум	90	89	89	7
Компрессор	Низкочастотные колебания	91	88	89	6
Клапан	Аномальные вибрации	93	92	92	4
Компрессор	Высокочастотные шумы	89	87	88	8
Вентилятор	Перегрев (шум вентиляции)	92	90	91	5
Конвейер	Прерывания работы	95	93	94	4
Электродвигатель	Аномальные звуки	88	85	86	10
Генератор	Перегрев	91	89	90	5
Вибрационный насос	Шумы из-за износа	90	87	88	7
Редуктор	Неправильное положение	92	91	91	3
Компрессор	Увеличенный уровень шума	89	86	87	9
Гидравлическая система	Протечки	93	92	92	5
Оборудование для упаковки	Неисправность механизмов	90	88	89	8

честве работы алгоритма в условиях реального применения.


Алгоритм был протестирован на различных типах промышленного оборудования. Основные типы неисправностей, которые анализировались в рамках экспериментов:

– вибрации (аномальные или аномально высокие);

– неравномерные или высокочастотные шумы;
– прерывания работы механизмов;
– протечки, трение и перегрев.

Групповая столбчатая диаграмма (рис. 2) сравнивает выбранные метрики для каждого типа оборудования.

Система продемонстрировала высокие результаты по всем метрикам. Точность и полнота



■ **Рис. 2.** Сравнение метрик для каждого типа оборудования

■ **Fig. 2.** Comparison of metrics for each type of equipment

большинства тестируемых устройств находятся в диапазоне 88–95 %, что свидетельствует о высокой надежности алгоритма. Средние значения F1-меры также подтверждают сбалансированную работу алгоритма, особенно в условиях обработки сложных звуковых данных.

Типы оборудования и точность обнаружения

Насосы. Алгоритм показал высокую эффективность в обнаружении вибраций и трения. Средняя F1-мера составляет 91,5 %, что отражает способность системы успешно распознавать как нормальные, так и неисправные состояния.

Вентиляторы. Неравномерные шумы и шумы, вызванные перегревом, распознавались с точностью 92 %, при этом уровень ложных срабатываний удерживался на уровне 5–7 %.

Компрессоры. Обнаружение низко- и высокочастотных шумов оказалось более сложной задачей, с точностью 89–91 %, что связано с высокой вариативностью акустических сигналов компрессоров.

Клапаны. Здесь система показала наилучшие результаты: точность 93 %, полнота 92 % и минимальные ложные срабатывания (4 %).

Уровень ложных срабатываний

Ложные срабатывания остались в пределах допустимых значений, не превышая 10 % даже в самых сложных случаях (например, для электродвигателей и компрессоров с высоким уровнем шума). Это говорит о том, что алгоритм обладает высокой устойчивостью к ошибкам, связанным с шумами окружающей среды.

Особые сценарии и устройства

Конвейеры и гидравлические системы продемонстрировали максимальную точность классификации (93–95 %), что объясняется более однородными акустическими характеристиками этих типов оборудования.

Электродвигатели и оборудование для упаковки показали более низкие результаты (средняя F1-мера 86–89 %) из-за сложности сигналов и высокой чувствительности к фоновым шумам.

Итог эксперимента

Многоагентный ансамблевый алгоритм продемонстрировал высокую эффективность в обнаружении неисправностей для широкого спектра оборудования. Наилучшие результаты достигнуты при работе с насосами, клапанами и гидравлическими системами, где удалось минимизировать ложные срабатывания и добиться высокой точности.

Несмотря на небольшое снижение точности для сложных сценариев, таких как аномальные звуки электродвигателей или высокочастотные шумы компрессоров, система сохраняет уверенность в классификации, обеспечивая значительное преимущество перед традиционными

подходами. Такой уровень производительности делает алгоритм пригодным для внедрения в реальные производственные системы, где требуются высокая надежность и точность диагностики.

Анализ нагрузки на компьютер и время выполнения алгоритма

Для успешного внедрения многоагентного ансамблевого алгоритма в реальные производственные системы важно учитывать вычислительную нагрузку, которую он создает на оборудование. Основные параметры, характеризующие нагрузку, включают загрузку центрального процессора (CPU), использование оперативной памяти (RAM) и время выполнения задачи. Эти показатели варьируются в зависимости от типа оборудования и характера неисправности, которые анализирует алгоритм. В табл. 2 и на рис. 3 представлены основные показатели нагрузки на компьютер и время выполнения алгоритма.

Загрузка CPU указывает на процент использования центрального процессора во время выполнения алгоритма. Например, для распознавания прерываний работы на конвейере наблюдается загрузка 65 %.

Загрузка RAM отображает объем оперативной памяти, используемой алгоритмом. В случае электродвигателя, например, используется 180 МБ.


Время выполнения — показатель времени, необходимого для выполнения алгоритма для каждого типа нарушения. Например, на распознавание шумов из-за износа вибрационного насоса уходит 3,2 с.

Потребление оперативной памяти отражает объем данных, который должен быть обработан алгоритмом одновременно. Наибольшее потребление памяти зафиксировано для электродвигателей (180 МБ) и оборудования для упаковки (175 МБ), что связано с большим числом характеристик, учитываемых при анализе аномалий. Наименьший объем памяти использовался для генератора при анализе перегрева (140 МБ) и гидравлической системы при обнаружении протечек (145 МБ). Эти данные подтверждают, что использование RAM остается в пределах, допустимых для большинства современных компьютерных систем, что делает алгоритм применимым даже на оборудовании среднего уровня.

Загрузка CPU характеризует интенсивность вычислительных операций, выполняемых алгоритмом. Наибольшая загрузка наблюдается при анализе сложных или многосоставных акустических сигналов, таких как аномальные звуки электродвигателей (70 %) и неисправности механизмов упаковочного оборудования (71 %).


■ **Таблица 2.** Нагрузка на компьютер и время выполнения■ **Table 2.** Computer load and execution time

Тип оборудования	Тип нарушения	Загрузка CPU, %	Загрузка RAM, МБ	Время выполнения, с
Конвейер	Прерывания работы	65	150	2,5
Электродвигатель	Аномальные звуки	70	180	3,0
Генератор	Перегрев	60	140	2,8
Вибрационный насос	Шумы из-за износа	68	160	3,2
Редуктор	Неправильное положение	64	155	2,7
Компрессор	Увеличенный уровень шума	69	170	3,1
Гидравлическая система	Протечки	66	145	2,9
Оборудование для упаковки	Неисправность механизмов	71	175	3,3

■ **Рис. 3.** Сравнение загрузки CPU, RAM и времени выполнения по типам оборудования■ **Fig. 3.** Comparison of CPU load, RAM usage, and execution time across equipment types

Минимальная нагрузка зафиксирована при обработке сигналов редуктора с некорректным положением (64 %) и конвейера с прерываниями работы (65 %). Такая вариативность обусловлена сложностью извлечения признаков из сигналов различной природы и необходимостью обработки большого объема данных для аномалий высокой сложности.

Время выполнения — один из важнейших факторов, особенно для систем реального времени. Зависимость времени выполнения алгоритма от загрузки CPU иллюстрирует рис. 4. Самое быстрое выполнение наблюдается при распознавании прерываний работы на конвейере (2,5 с) и неправильного положения редуктора (2,7 с). Максимальное время выполнения потребовалось для анализа шумов из-за износа вибра-

■ **Рис. 4.** Зависимость времени выполнения от загрузки CPU■ **Fig. 4.** Dependence of execution time on CPU load

ционного насоса (3,2 с) и неисправности механизмов упаковочного оборудования (3,3 с).

В случае внедрения описанного алгоритма на практике рекомендуется применение вычислительной системы, параметры которой обеспечат время отклика, приемлемое для соответствующей предметной области. В частности, возможно применение аппаратного ускорения (GPU/TPU). Время реакции системы также может быть дополнительно оптимизировано за счет уменьшения сложности моделей агентов (например, замены традиционной сверточной нейронной сети на MobileNet) и параллелизации вычислений.

Заключение

В рамках проведенного исследования был разработан и протестирован многоагентный ансамблевый алгоритм для акустического распознава-

ния нарушений работоспособности автономного технологического оборудования. Многоагентный алгоритм базируется на интеграции нескольких специализированных агентов, каждый из которых анализирует определенные аспекты акустического сигнала, а также на использовании механизмов ансамблевого обучения для повышения точности и надежности системы.

Основным элементом новизны работы является сочетание многоагентного подхода с адаптивными ансамблевыми методами, которые учитывают индивидуальные сильные стороны каждого агента и динамически изменяют их вес при принятии решений. Введенные механизмы регуляризации и прогрессивного изменения коэффициентов, управляющих обучением, позволяют снизить вероятность переобучения и повысить устойчивость системы к внешним воздействиям. Кроме того, использование инновационных методов обработки сигналов, таких как динамическое дисконтирование наград и учет неопределенности через UCB (Upper Confidence Bound), вносит вклад в развитие алгоритмов обнаружения аномалий.

Разработанный алгоритм может быть эффективно применен в системах мониторинга состояния автономного технологического оборудования [20]. Он обеспечивает высокую точность распознавания аномальных звуков, что критически важно для своевременного выявления неисправностей и предотвращения аварий. Система также адаптируется к различным условиям эксплуатации и способна обрабатывать акустические данные в реальном времени, что делает ее подходящей для применения в промышленных условиях, где требуется минимизация времени простоя оборудования.

Тестирование алгоритма выявило несколько ограничений, которые требуют дальнейшей разработки:

— снижение точности в условиях высоких уровней шума. Внешние акустические помехи, особенно схожие с частотными характеристиками неисправностей, приводят к повышению числа ложных срабатываний. Это указывает на необходимость разработки более устойчивых методов фильтрации и разделения сигналов;

— ограничения при анализе редких или новых типов неисправностей. Отсутствие достаточного количества тренировочных данных для таких случаев ограничивает возможности системы. Дальнейшие исследования могут быть направлены на использование методов генеративного обучения для синтеза данных;

— высокие вычислительные требования. Многоагентная структура, хотя и обеспечивает высокий уровень точности, требует значительных ресурсов, что делает ее неприменимой для оборудования с низкой производительностью. В этом направлении целесообразно исследовать механизмы оптимизации вычислений и аппаратных реализаций.

Для обработки более сложных сигналов (например, высокочастотных шумов) целесообразно использовать оптимизированные библиотеки или вычислительные ускорители, такие как GPU или TPU. Встроенные механизмы регулировки параметров алгоритма (например, снижение разрешения спектрограммы) могут дополнительно уменьшить вычислительную нагрузку при минимальных потерях в точности.

Несмотря на существующие ограничения, разработанный многоагентный ансамблевый алгоритм демонстрирует практическую значимость и потенциал для применения в промышленных системах диагностики. Дальнейшие усилия по устранению выявленных недостатков и адаптации системы к более широкому спектру задач позволят расширить ее функциональные возможности и применимость в условиях реальной эксплуатации.

Литература

1. Zonzini F., Bogomolov D., Dhamija T., Testoni N., De Marchi L., Marzani A. Deep learning approaches for robust time of arrival estimation in acoustic emission monitoring. *Sensors*, 2022, vol. 22, no. 3, Article 1091. doi.org/10.3390/s22031091
2. Митр Д. В. Распознавание типа наземной техники по акустическому сигналу на основе алгоритма с временной кодировкой. *Будущее машиностроения России: сборник докладов XV Всероссийской конференции молодых ученых и специалистов (с международным участием)*, Москва, 21–24 сентября 2022 г. М., 2023, т. 2, с. 234–236.
3. Верзун Н. А., Колбанев М. О., Салиева А. Р. Анализ перспектив обучения умных автономных логи-

стических систем на основе оптимизации функции ценности. *Известия СПбГЭТУ «ЛЭТИ»*, 2024, т. 17, № 10, с. 28–39. doi:10.32603/2071-8985-2024-17-10-28-39

4. Yang Z., Ma N., Yao Y. A survey on cooperative control of multi-agent systems. *Proceedings of 2023 2nd International Conference on Artificial Intelligence, Human-Computer Interaction and Robotics (AIHCIR)*, 2023, pp. 501–515. doi.org/10.1109/AIHCIR61661.2023.00090
5. Kalech M., Khalastchi E. On fault detection and diagnosis in robotic systems. *ACM Computing Surveys*, 2018, vol. 51, no. 1, Article 9. doi.org/10.1145/3146389
6. Wang J., Zhou J., Chen X. *Data-Driven Fault Detection and Reasoning for Industrial Monitoring*. Springer

- er Singapore, 2022. 264 p. doi.org/10.1007/978-981-16-8044-1
7. Jombo G., Zhang Y. Acoustic-based machine condition monitoring — Methods and challenges. *Eng.*, 2023, vol. 4, no. 1, pp. 47–79. doi.org/10.3390/eng4010004
 8. Бережнов Н. И., Сирота А. А. Универсальный алгоритм улучшения изображений с использованием глубоких нейронных сетей. *Вестник ВГУ. Серия: Системный анализ и информационные технологии*, 2022, № 2, с. 81–92. doi:10.17308/sait/1995-5499/2022/2/81-92
 9. Харламов А. А. Анализ текстов с использованием искусственных нейронных сетей на основе нейроподобных элементов с временной суммацией сигналов (часть 1). *Речевые технологии*, 2023, № 1, с. 87–99. <https://speechtechnology.ru/assets/files/1-2023.pdf> (дата обращения: 20.02.2025).
 10. Mastella M., Thiemens T., Cicca E. Texture recognition using a biologically plausible spike phase-locked loop model for spike train frequency decomposition. *arXiv preprint*, 2024. arXiv:2403.09723. doi:10.48550/arXiv.2403.09723
 11. Marin O., Sens P., Briot J.-P., Guessoum Z. Towards adaptive fault tolerance for distributed multi-agent systems. *Proceedings of the 4th European Seminar on Advanced Distributed Systems (ERSADS '2001)*, 2001, pp. 195–201.
 12. Jaros R., Byrtus R., Dohnal J., Danys L., Baros J., Koziorek J., Zmij P., Martinek R. Advanced signal processing methods for condition monitoring. *Archives of Computational Methods in Engineering*, 2022, vol. 30, no. 1. doi:10.1007/s11831-022-09834-4
 13. Belhadi A., Djenouri Y., Srivastava G., Lin J. C.-W. Reinforcement learning multi-agent system for faults diagnosis of microservices in industrial settings. *Computer Communications*, 2021, vol. 177, pp. 213–219. doi:10.1016/j.comcom.2021.07.010
 14. Liu Y., Ding W., Feng Y., Guo Y. Ensembled mechanical fault recognition system based on deep learning algorithm. *Journal of Vibroengineering*, 2021, vol. 23, no. 6, pp. 1318–1331. doi:10.21595/jve.2021.21944
 15. Maldonado D., Cruz E., Torres J. A., Cruz P. J., Benitez S. D. P. G. Multi-agent systems: A survey about its components, framework and workflow. *IEEE Access*, 2024, vol. 12, pp. 80950–80975. doi:10.1109/ACCESS.2024.3409051
 16. Shahid M. H. B., Azim A. Ensemble method for fault detection & classification in transmission lines using ML. *Proceedings of the 2023 IEEE International Systems Conference (SysCon)*, 2023, pp. 1–7. doi:10.1109/SysCon53073.2023.10131138
 17. Sutton R. S., Barto A. G. (2014–2015). *Reinforcement Learning: An Introduction* (2nd ed.). Cambridge, MIT Press, 2014–2015. 338 p.
 18. Lattimore T., Szepesvári C. *Bandit Algorithms*. Draft, 2018. 513 p.
 19. Powers D. M. W. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness, and correlation. *Journal of Machine Learning Technologies*, 2011, vol. 2, no. 1, pp. 2229–3981. doi:10.9735/2229-3981
 20. Салиева А. Р., Верзун Н. А., Колбанев М. О. Оптимизация стратегии в алгоритмах обучения с подкреплением в логистических системах принятия решений. *Известия СПбГЭТУ «ЛЭТИ»*, 2025, т. 18, № 3, с. 65–77. doi: 10.32603/2071-8985-2025-18-3-65-77

UDC 004.896

doi:10.31799/1684-8853-2025-3-14-24

EDN: VHOSZZ

Multi-agent ensemble algorithm for acoustic recognition of malfunctions of autonomous technological equipment

N. A. Verzun^{a,b}, PhD, Tech., Associate Professor, orcid.org/0000-0002-0126-2358, verzun.n@unecon.ru

M. O. Kolbanev^{a,b}, Dr. Sc., Tech., Professor, orcid.org/0000-0003-4825-6972

A. R. Salieva^a, Post-Graduate Student, orcid.org/0009-0001-9519-5773

^aSaint-Petersburg Electrotechnical University «LETI», 5, Prof. Popov St., 197376, Saint-Petersburg, Russian Federation

^bSaint-Petersburg State University of Economics, 30-32, Griboedov canal Emb., 191023, Saint-Petersburg, Russian Federation

Introduction: In highly automated production, traditional methods of diagnostics of process equipment operation based on visual inspection or mechanical sensors are often insufficient. Taking into account autonomous modes of equipment using artificial intelligence, automatic monitoring systems that use acoustic data, capable of signaling faults without interfering with the operation process, are becoming increasingly important. **Purpose:** To develop a multi-agent ensemble algorithm for acoustic recognition capable of identifying various types of disturbances in the operation of autonomous technical systems with an accuracy of at least 90%, an F1-measure of ≥ 0.85 .

Results: We propose a new approach to acoustic recognition of faults in autonomous process equipment based on a multi-agent ensemble algorithm. We develop the architecture of a multi-agent system, including four specialized agents that analyze various parameters of acoustic signals: 1) a spectral analysis agent evaluates changes in the frequency content of the acoustic signal, identifying abnormal oscillations characteristic of mechanical damage and malfunctions; 2) a temporal analysis agent tracks time patterns of acoustic data, analyzing changes in the amplitude and duration of signals, which allows identifying short-term failures and irregular noises; 3) an equipment performance analysis agent correlates acoustic data with the equipment operating modes, identifying deviations from normal

operation; 4) an external environment analysis agent takes into account external noise factors and filters them, increasing the accuracy of diagnostics by eliminating extraneous sounds. The agents are implemented and trained using machine and deep learning methods. As part of the study, we conduct an experiment in which the effectiveness of the proposed algorithm is assessed. The accuracy of fault recognition has reached at least 90%. The conducted study shows that the use of a multi-agent approach makes it possible to increase the reliability of diagnostics by combining the results of various analytical models. **Practical relevance:** The program code implementing the ensemble recognition algorithm can be used to diagnose a wide range of autonomous systems.

Keywords – acoustic recognition, autonomous technological equipment, ensemble algorithm, empirical mode decomposition.

For citation: Verzun N. A., Kolbanov M. O., Salieva A. R. Multi-agent ensemble algorithm for acoustic recognition of malfunctions of autonomous technological equipment. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 14–24 (In Russian). doi:10.31799/1684-8853-2025-3-14-24, EDN: VHOSZZ

References

- Zonzini F., Bogomolov D., Dhamija T., Testoni N., De Marchi L., Marzani A. Deep learning approaches for robust time of arrival estimation in acoustic emission monitoring. *Sensors*, 2022, vol. 22, no. 3, Article 1091. doi.org/10.3390/s22031091
- Mitr D. V. Recognition of ground equipment type by acoustic signal based on time-encoded algorithm. *Sbornik dokladov XV Vserossijskoj konferencii molodyh uchyonyh i specialistov (s mezhdunarodnym uchastiem) "Budushchee mashinostroeniya Rossii"* [Proc. XV All-Russian Conf. "The future of Russian engineering"]. Moscow, 2023, vol. 2, pp. 234–236 (In Russian).
- Verzun N. A., Kolbanov M. O., Salieva A. R. Analysis learning prospects of smart autonomous logistics systems based on value function optimization. *Izvestiya SPbGETU "LETI"*, 2024, vol. 17, no. 10, pp. 28–39 (In Russian). doi:10.32603/2071-8985-2024-17-10-28-39
- Yang Z., Ma N., Yao Y. A survey on cooperative control of multi-agent systems. *Proceedings of 2023 2nd International Conference on Artificial Intelligence, Human-Computer Interaction and Robotics (AIHCIR)*, 2023, pp. 501–515. doi.org/10.1109/AIHCIR61661.2023.00090
- Kalech M., Khalastchi E. On fault detection and diagnosis in robotic systems. *ACM Computing Surveys*, 2018, vol. 51, no. 1, Article 9. doi.org/10.1145/3146389
- Wang J., Zhou J., Chen X. *Data-Driven Fault Detection and Reasoning for Industrial Monitoring*. Springer Singapore, 2022. 264 p. doi.org/10.1007/978-981-16-8044-1
- Jombo G., Zhang Y. Acoustic-based machine condition monitoring – Methods and challenges. *Eng.*, 2023, vol. 4, no. 1, pp. 47–79. doi.org/10.3390/eng4010004
- Berezhnov N. I., Sirota A. A. Universal image enhancement algorithm using deep neural networks. *Proceedings of VSU. Series: Systems Analysis and Information Technologies*, 2022, no. 2, pp. 81–92 (In Russian). doi:10.17308/sait/1995-5499/2022/2/81-92
- Kharlamov A. A. Text analysis using artificial neural networks based on neural-like elements with time summation of signals (part 1). *Rechevye tekhnologii*, 2023, no. 1, pp. 87–99. Available at: <https://speechtechnology.ru/assets/files/1-2023.pdf> (accessed 20 February 2025) (In Russian).
- Mastella M., Thiemens T., Cicca E. Texture recognition using a biologically plausible spike phase-locked loop model for spike train frequency decomposition. *arXiv preprint*, 2024. arXiv:2403.09723. doi:10.48550/arXiv.2403.09723
- Marin O., Sens P., Briot J.-P., Guessem Z. Towards adaptive fault tolerance for distributed multi-agent systems. *Proceedings of the 4th European Seminar on Advanced Distributed Systems (ERSADS '2001)*, 2001, pp. 195–201.
- Jaros R., Byrtus R., Dohnal J., Danyš L., Baros J., Koziorek J., Zmij P., Martinek R. Advanced signal processing methods for condition monitoring. *Archives of Computational Methods in Engineering*, 2022, vol. 30, no. 1. doi:10.1007/s11831-022-09834-4
- Belhadi A., Djenouri Y., Srivastava G., Lin J. C.-W. Reinforcement learning multi-agent system for faults diagnosis of microservices in industrial settings. *Computer Communications*, 2021, vol. 177, pp. 213–219. doi:10.1016/j.comcom.2021.07.010
- Liu Y., Ding W., Feng Y., Guo Y. Ensembled mechanical fault recognition system based on deep learning algorithm. *Journal of Vibroengineering*, 2021, vol. 23, no. 6, pp. 1318–1331. doi:10.21595/jve.2021.21944
- Maldonado D., Cruz E., Torres J. A., Cruz P. J., Benitez S. D. P. G. Multi-agent systems: A survey about its components, framework and workflow. *IEEE Access*, 2024, vol. 12, pp. 80950–80975. doi:10.1109/ACCESS.2024.3409051
- Shahid M. H. B., Azim A. Ensemble method for fault detection & classification in transmission lines using ML. *Proceedings of the 2023 IEEE International Systems Conference (SysCon)*, 2023, pp. 1–7. doi:10.1109/SysCon53073.2023.10131138
- Sutton R. S., Barto A. G. *Reinforcement Learning: An Introduction* (2nd ed.). Cambridge, MIT Press, 2014–2015. 338 p.
- Lattimore T., Szepesvári C. *Bandit Algorithms*. Draft, 2018. 513 p.
- Powers D. M. W. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness, and correlation. *Journal of Machine Learning Technologies*, 2011, vol. 2, no. 1, pp. 2229–3981. doi:10.9735/2229-3981
- Salieva A. R., Verzun N. A., Kolbanov M. O. Strategy optimization in reinforcement learning algorithms in logistic decision-making systems. *Izvestiya SPbGETU "LETI"*, 2025, vol. 18, no. 3, pp. 65–77. doi:10.32603/2071-8985-2025-18-3-65-77



Обработка информационных последовательностей с использованием адаптивного анализа сегментов при оценке состояния систем

И. С. Лебедев^а, доктор техн. наук, профессор, orcid.org/0000-0001-6753-2181, isl_box@mail.ru

^аСанкт-Петербургский Федеральный исследовательский центр РАН, 14-я линия В.О., 39, Санкт-Петербург, 199178, РФ

Введение: формирование и разметка выборок является трудоемкой процедурой, играющей важную роль в процессах обучения с учителем и настройки большого количества моделей машинного обучения. При решении задач с применением методов искусственного интеллекта достаточно часто возникает необходимость снизить затраты на маркировку данных. **Цель:** повысить качество обработки информационных последовательностей за счет формирования, анализа и определения сегментов последовательностей данных, на которых заранее заданными алгоритмами машинного обучения достигаются лучшие показатели качества. **Результаты:** предложен метод формирования сегментов информационной последовательности на основе анализа показателей качества моделей обработки, отличающийся от известных, осуществляющих настройку моделей машинного обучения на обрабатываемые данные, разделением последовательности на сегменты и выбором способа сегментирования таким образом, чтобы свойства полученных в сегменте данных как можно лучше соответствовали модели обработки. В отличие от классического подхода, когда модель настраивается на данные, в предлагаемом методе сегментированием последовательности данные настраиваются под модель. **Практическая значимость:** результаты могут быть использованы в моделях и методах, решающих задачи классификации и прогнозирования. Предложенный метод позволяет частично преодолевать ряд проблемных вопросов, связанных с маркировкой выборок данных. В результате становится возможным обучать модели, используя выборки, которые имеют частичные или неточные метки, а также снизить затраты на процесс разметки. Дальнейшее развитие предложенного решения возможно на основе ансамблевых методов.

Ключевые слова — машинное обучение, адаптивные модели, повышение качества обработки, адаптивная обработка сегментов последовательностей.

Для цитирования: Лебедев И. С. Обработка информационных последовательностей с использованием адаптивного анализа сегментов при оценке состояния систем. *Информационно-управляющие системы*, 2025, № 3, с. 25–36. doi:10.31799/1684-8853-2025-3-25-36, EDN: SSGKZU

For citation: Lebedev I. S. Sequential information processing using adaptive pattern analysis in assessing the state of systems. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 25–36 (In Russian). doi:10.31799/1684-8853-2025-3-25-36, EDN: SSGKZU

Введение

Традиционные подходы машинного обучения «с учителем» нуждаются в большом количестве размеченных данных. Однако из-за различных факторов, таких как шум, большая размерность признаков, неоднозначность классификации состояния, разметка выборок больших объемов может являться трудоемкой задачей. В связи с этим возникает необходимость в разработке методов обучения на малом количестве данных.

Часто выборки данных трудно интерпретируются для обучения моделей, что приводит к развитию методов слабоконтролируемого обучения, выявляющего значимые шаблоны, паттерны, неявные закономерности данных без участия человека [1]. Слабоконтролируемое обучение направлено на снижение затрат на маркировку данных. Его использование в ряде практических задач может помочь уменьшить потребность в боль-

ших объемах помеченных данных в условиях необходимости достижения относительно высоких качественных показателей обработки, где процессы разметки затруднены [2].

Формирование пространства признаков нередко имеет значение в обработке данных. Оно играет важную роль в повышении качества результатов, снижении вычислительной сложности.

Методы и модели обработки последовательностей

Повышение показателей качества обработки данных является одной из фундаментальных задач методов машинного обучения. Основное направление решения связано с формированием эффективных моделей обработки данных [3–5]. Достижимые значения показателей качества обработки базовых алгоритмов, таких как, например, наивный байесовский классификатор,

линейный дискриминант, деревья решений, зависят от свойств обрабатываемых выборок. В случае изменения распределений, частоты событий, трендов простые модели могут терять свою адекватность.

Для нивелирования подобных недостатков и повышения качества обработки информационных последовательностей применяются подходы, направленные на формирование ансамблей моделей и алгоритмов, сочетающих несколько методов машинного обучения [6, 7] (табл. 1 [8]).

Помимо приведенных в таблице ансамблевых методов, при формировании сложных многоуровневых моделей могут использоваться системы выборочного, взвешенного голосования; системы принятия решений, основанные на правилах, априорных знаниях о данных; каскады простых моделей и глубоких нейронных сетей [9–11]. Основными их недостатками являются сложность обучения, агрегации результатов, ресурсоемкость и увеличение времени работы алгоритмов. Неправильно подобранные модели и способы агрегации их результатов могут приводить к ухудшению общего прогноза.

Другое направление повышения качественных показателей обработки связано с формированием пространства признаков. Его обосно-

вание осуществляется с помощью качественных показателей. Это могут быть различные статистические метрики, например измерения расстояния, меры согласованности, меры корреляции, меры на основе теории информации, либо функции потерь и функционалы качества в методах машинного обучения [12–15]. В небольших наборах данных вычисление ряда статистических метрик может быть затруднено или непрактично.

Среди методов, формирующих пространство признаков для задач обработки данных, можно выделить решения, разделяющие данные на основе кластеризации, динамического программирования, бинарной сегментации, байесовские методы [16–24]. Таких методов довольно много.

Основные подходы к сегментации последовательности, разделяющей ее на подпоследовательности, и их характеристики представлены в табл. 2.

На основе описанных подходов реализуются различные методы разделения последовательностей.

Применение методов зависит от вида и свойств обрабатываемой информации. Целью таких подходов является повышение выбранных показателей качества моделей обучения за счет определения дополнительной информации.

■ **Таблица 1.** Характеристики основных ансамблевых методов

■ **Table 1.** Characteristics of the main ensemble methods

Основные ансамблевые методы	Предпосылки к применению	Возможные ограничения
Bagging	Уменьшает влияние ошибок одной модели, повышая общую точность ансамбля; снижает чувствительность при трансформации свойств данных; позволяет осуществлять параллельное обучение моделей обработки	В случае «неправильно» подобранных моделей может ухудшить результат; при обучении сложных моделей требует значительных вычислительных ресурсов
Boosting	Устойчив к переобучению, применяется при работе с несбалансированными выборками данных	Имеет «склонность» к переобучению, обладает существенной вычислительной сложностью; при решении практических задач получаются сложные композиции, которые тяжело настраиваются
AdaBoost	Обладает устойчивостью к зашумленным и несбалансированным данным	Чувствителен к выбросам
Gradient Boosting	Более других моделей устойчив к ошибкам и пропускам данных	Крайне чувствителен к выбросам и при их наличии тратит огромное количество ресурсов
Stacking	Обладает устойчивостью к переобучению, позволяет создавать многоуровневые модели	Характеризуется значительным ростом вычислительной сложности при увеличении количества моделей
Hybrid Ensemble	Обладает относительно высокой точностью и универсальностью при обработке выборок с различными свойствами	Зависим от качества и количества данных; имеется сложность настройки моделей

■ **Таблица 2.** Характеристики основных подходов разделения последовательности■ **Table 2.** Major approaches characteristics of sequence separation

Метод разделения последовательности	Характеристика
Скольльзящие окна	Сегмент увеличивается до тех пор, пока не превысит некоторую границу, далее процесс повторяется со следующей точкой данных, не включенной в новый аппроксимированный сегмент
Сверху вниз	Информационная последовательность рекурсивно разделяется до момента выполнения заранее заданных критериев остановки
Снизу вверх	Начиная с максимально возможного приближения, сегменты объединяются, пока не будут выполнены заранее заданные критерии остановки
Линейная интерполяция	По заранее определенным характеристикам формируются аппроксимирующие линии для последовательности и на их основе определяются сегменты
Неконтролируемый подход, основанный на глубоком обучении	Применяются методы машинного обучения для автоматического извлечения знаний из последовательностей и определения сегментов
Сегментация на основе шаблонов	Формируется «словарь» шаблонов, на основе которого происходит определение сегментов информационной последовательности
Сегментация на основе пороговых значений	Обрабатываются заранее заданные характеристики информационной последовательности, отслеживаются пороговые значения для определения границ сегментов
Сегментация на основе периодичности	Определяется периодичность в последовательности для определения границ сегментов

Характеристики предлагаемого метода

В результате применения разных методов разделения последовательности получаются сегменты, обладающие информацией с разными свойствами. Свойства сегмента зависят от количества объектов наблюдения, их распределений, трендов, периодичности. Достигаемые показатели качества модели обработки обусловлены свойствами информации на сегменте. Для одного способа разбиения последовательности на сегменты лучшие результаты покажут одни модели, при выборе другого метода разбиения или изменении его параметров — другие.

В классических подходах машинного обучения происходит «настройка» моделей обучения на свойства обучающей выборки.

В представляемом решении рассматривается обратная задача формирования сегментов последовательностей данных таким образом, чтобы их свойства соответствовали модели обработки.

Предлагается метод формирования информационных подпоследовательностей на основе анализа показателей качества моделей обработки, отличающийся от известных, осуществляющих настройку моделей машинного обучения на обрабатываемые данные, разделением последовательности на сегменты и выбором способа сегментирования так, чтобы свойства полученных

в сегменте данных лучшим образом соответствовали модели обработки.

В отличие от классического подхода, когда модель настраивается на данные, в предлагаемом методе анализом и выбором сегментов последовательности данные формируются под модель.

Определение свойств информации последовательности на первоначальных этапах анализа может быть затруднительным, иметь высокую вычислительную сложность, а в случае явления «дрейфа концепта» являться малоэффективным. Поэтому для повышения показателей качества обработки необходимо определять не просто модель обработки, а модель совместно с методом разделения последовательности.

Назначение моделей на сегменты, полученные разными методами разделения последовательности, происходит на основе выбранного показателя качества. Выбор показателя качества зависит от решаемой задачи. В более сложных моделях обработки возможно применять алгоритмы адаптивного взвешивания с учетом вклада различных признаков данных в сегментах, например на основе значений Шепли.

В случае нахождения адекватной модели для свойств информации сегмента становится возможным повысить функционал качества обработки, а в перспективе — уменьшить количество примеров для обучения.

В результате применения метода вначале происходит выбор способа разделения последовательности с одновременным использованием заранее определенного показателя качества модели обработки, а уже как следующий шаг — формирование агрегированной модели, состоящей из алгоритмов, достигающих лучших качественных показателей на сегментах.

Постановка задачи обработки информационных потоков

Поступающие на вход моделей обработки выборки могут представлять собой данные с разнообразными структурами, имеющими неявные закономерности в распределениях, дисбаланс классов и частот появления событий, изменения диапазонов значений переменных под воздействием неопределенных факторов.

Формальную постановку можно представить следующим образом. X — выборка данных, состоящая из последовательностей, полученных в различных состояниях: $\{X^1, \dots, X^l, \dots, X^L\} \in X$, где X^l — последовательность значений, полученных в состоянии l .

Последовательность данных может быть разделена разными способами. Функции разбиения последовательности $\{\mu_1, \dots, \mu_k\} \in \mu$ формируют подпоследовательности на основе различных алгоритмов и методов. Это могут быть решения, основанные на анализе трендов, сезонности, частотных составляющих, методах автокорреляции, скользящих окон и т. д. В зависимости от свойств данных и решаемых задач можно считать, что формирование сегментов последовательностей возможно $k = 1, \dots, K$ способами.

Функция разбиения $\mu_k : X^l \rightarrow \{X_1^{lk}, \dots, X_m^{lk}\}$ разделяет последовательность $X^l \in X$ в состоянии l на подпоследовательности.

В результате применения функций разбиения меняются состав и свойства подпоследовательностей $X_i^{lk} \in X^l \in X$, количество содержащихся в них объектов наблюдения. А это приводит к тому, что различным способам разделения последовательности будут соответствовать свои модели, достигающие лучших качественных показателей, из заранее предопределенного множества $\{a_1, \dots, a_N\} \in a$.

Способы $\{\mu_1, \dots, \mu_k\} \in \mu$ разбиения последовательности будут приводить к разным качественным показателям обработки алгоритмов. Кроме того, если выбирать модели $\{a_1, \dots, a_n, \dots, a_N\} \in a$, то результат обработки последовательности X , разделенной на подпоследовательности, зависит и от модели a_n , и от способа μ_k формирования сегмента.

Таким образом, для последовательности X необходимо осуществить выбор способа формиро-

вания подпоследовательности μ_k и модели a_n , где функционал качества стремится к максимальному значению:

$$Q(a_n, X, \mu_k) \rightarrow \max_{k,n}. \quad (1)$$

Возникает задача обработки информационной последовательности, в которой предлагаемый метод использует оценку показателей качества моделей обработки на сегментах, обладающих разными свойствами данных. Происходит выбор способа разделения и полученных сегментов, на которых модель может приобрести лучшие показатели качества.

Реализация предлагаемого метода

Реализация метода предполагает выполнение ряда шагов по формированию подпоследовательностей и их обработке. На рис. 1 представлен алгоритм действий для выбора способа разделения информационной последовательности и модели обработки, показывающей лучшие значения показателя качества.

Первоначально подготавливается обучающая выборка $\{X^1, \dots, X^l, \dots, X^L\} \in X$ последовательности данных для различных состояний. Определяются и формируются модели обработки $\{a_1, \dots, a_n, \dots, a_N\} \in a$ и задаются методы разделения $\{\mu_1, \dots, \mu_k\} \in \mu$. Затем для каждой модели a_n и для каждого способа μ_k выполняются обучение и оценка функционала качества $Q(a_n, X, \mu_k)$. Полученные результаты для каждой модели a_n и для каждого способа μ_k сохраняются. После выполнения циклов перебора моделей и подпоследовательностей осуществляется выбор модели обработки и способа формирования сегментов, на которых получены лучшие значения показателя качества.

Решение задачи, определяемой выражением (1), предполагает большое количество повторяющихся рутинных операций формирования последовательностей данных для обучения, анализа результатов на различных этапах реализации и выбора модели обработки.

Формируемые подпоследовательности могут обладать различными характеристиками, на которых лучшие показатели качества могут демонстрировать разные модели.

Определение лучшего значения функционала качества в простейшем случае может решаться методом прямого перебора. В таком алгоритме максимальное число рассматриваемых подпоследовательностей последовательности равно M^2 . Условно накладные расходы на усредненное время обучения и обработки для модели a_n на подпоследовательности можно оценить величиной p ,



■ **Рис. 1.** Последовательность шагов метода
 ■ **Fig. 1.** The method sequence steps

общая вычислительная сложность алгоритма составляет $O(pNM^2)$. Количество моделей обработки N — обычно относительно небольшие величины. На рост сложности влияет число рассматриваемых подпоследовательностей M , что является существенным ограничением предлагаемого метода.


Однако в целях оптимизации и ускорения алгоритмов обработки можно применить ряд подходов, направленных на анализ и объединение «сходных» по свойствам подпоследовательностей, отбрасывание способов разбиения выборки при достижении значений качественных показателей обучения моделей заданного порога, распараллеливание процессов обучения для моделей.

Предлагаемый метод может быть применен в системах многоуровневой обработки [8, 25] для настройки моделей, использован в самообучающихся моделях. Реализация процессов самообучения и самонастройки предполагает ряд шагов. Поступающий на вход информационный поток подвергается обработке. Производится анализ и вычисление свойств объектов наблюдения. Выбирается заранее определенная модель, имеющая лучшие значения функционала качества. Результаты сравниваются с реальными значениями объектов наблюдения, полученными от регистрирующих систем и устройств. В случае увеличения ошибок выше заранее определенного порога принимается решение о формировании выборки данных. Над выборкой проводятся «манипуляции» по разделению на подпоследовательности, происходит настройка, обучение и назначение моделей на сегмент.

Экспериментальная оценка предлагаемого метода

Сравнение качественных показателей выполнялось для модельных данных и различных выборок [26, 27]. Пример анализируемой в эксперименте информационной последовательности представлен на рис. 2.

В приводимых в статье экспериментальных примерах рассматривается один из простых случаев, когда при обработке информационной последовательности формируются подпоследовательности путем выбора оптимальной длины и сдвига, а затем выполняются обучение моделей обработки и



■ **Рис. 2.** Пример информационной последовательности
 ■ **Fig. 2.** Information sequences example

анализ достигаемых ими качественных показателей. Выбор способа формирования подпоследовательности и модели происходит путем выявления лучших значений функционала качества.

Способ формирования и обработки подпоследовательностей для эксперимента представлен на рис. 3.

Для оценки качественных показателей обработки информационных последовательностей с применением описанного метода в качестве базовых моделей в зависимости от задачи обработки можно использовать алгоритмы любой сложности. В приводимом эксперименте при их выборе приоритет отдавался моделям, имеющим высокую скорость обучения. Сравнивались результаты наивного байесовского классификатора (NB), линейного дискриминанта (LD), машины опорных векторов (SVM), метода К-ближайших соседей (KNN), деревьев решений (DT) и ансамбля алгоритмов (ENS), включающего в себя все перечисленные методы. Цель эксперимента состояла в том, чтобы проанализировать качественные показатели моделей при формировании подпоследовательностей с различными свойствами, имеющих разные характеристики размера окна и сдвига. Оценка предлагаемого метода осуществлялась для задачи классификации.

Показатели качества обработки данных определялись метриками точности (Precision), полноты (Recall) и F-меры:

$$Pr = \frac{TP}{TP + FP} \times 100\%; \quad (2)$$


$$Rec = \frac{TP}{TP + FN} \times 100\%; \quad (3)$$

$$F1 = \frac{2 \times Pr \times Rec}{Pr + Rec} \times 100\%. \quad (4)$$

В эксперименте выборка последовательности каждого состояния разделялась в соотношении 70:30 на обучающую и тестовую, размер окна варьировался от двух до 50 отсчетов. На выбранных размерах окна выполнялись сдвиги, количество сдвигов соответствовало длине окна, т. е. для окна длиной два отсчета получалось два варианта разбиения, три отсчета — три варианта и т. д.


Диаграммы результатов зависимости, достигаемой алгоритмами точности (2), от длины подпоследовательностей, полученных в разных состояниях, и сдвига представлены на рис. 4. Каждый вариант разбиения длины окна дает свои значения точности, что отражает разброс по вертикали. Для фиксированной длины окна при различных сдвигах можно увидеть, что полученные значения точности (2) могут существенно расходиться.

Достижимые качественные показатели зависят от длины окна. Если размер подпоследовательности слишком мал, то значимые для алгоритма характеристики могут быть не обнару-



■ **Рис. 3.** Формирование и обработка подпоследовательностей

■ **Fig. 3.** Subsequences formation and processing



■ **Рис. 4.** Результаты метрики точности Precision классифицирующих алгоритмов для сегментов с разными длинами x и сдвигами

■ **Fig. 4.** The results of the classifying algorithms Precision metric for segments with different lengths x and shifts

жены. Если размер слишком большой, то характеристики могут быть пропущены. Уменьшение или увеличение длины подпоследовательности целесообразно в определенных границах. После выхода за границы существенного прироста качественных показателей моделей обработки данных не происходит.

Зависимости на рис. 4 показывают, что на рассматриваемых данных для всех классифицирующих алгоритмов лучших результатов можно достичь при определенных сдвигах на длине окна от 25 до 48 объектов наблюдения. Затем происходит стабилизация результатов.

Оценка показателей качества всех вариантов длин и сдвигов дает возможность выбрать подходящий способ формирования сегментов.

Кроме того, графики рис. 4 показывают, что различные алгоритмы обработки имеют разную чувствительность к изменению данных, связанных со сдвигом. Классифицирующие алгоритмы SVM, LD, NB демонстрируют большие разбросы значений качественных показателей в зависимости от способов формирования данных внутри окна определенной длины. Алгоритмы DT, KNN и ансамбль ENS имеют относительно небольшие разбросы по сравнению с первыми.


Разделение на подпоследовательности выборок данных может повысить качественные пока-

затели обработки модели. Свойства получаемых разными способами подпоследовательностей могут различаться, в связи с чем при их обработке алгоритмы могут достигать разных значений показателей качества.

Далее в эксперименте произведена оценка влияния соотношения объема обучающей и тестовой частей выборки на достигаемые качественные показатели для разных способов формирования подпоследовательностей. Были выделены длины окон и сдвиги, определяющие максимальное, среднее и минимальное значение точности. Значения точности (2) в зависимости от процентного соотношения «промаркированной» информации (обучающей и тестовой выборки) приведены на рис. 5.

Результаты демонстрируют влияние свойств информации сформированных подпоследовательностей на достигаемые показатели классифицирующих алгоритмов. На экспериментальных данных для всех моделей при разных соотношениях обучающей и тестовой выборки можно выделить подпоследовательности, на которых будет наблюдаться более высокий качественный показатель по сравнению с другими.

Для длин окон и сдвигов, на которых получены максимальное, среднее и минимальное значение точности (2), увеличение обучающей



■ **Рис. 5.** Значения точности Precision в зависимости от объема обучающей выборки для подпоследовательностей при разных сдвигах

■ **Fig. 5.** Precision accuracy values depending on the size of the training sample for the subsequences at different shifts

выборки приводит к улучшению результата показателя качества. Однако изначально «неудачно» выбранная подпоследовательность приводит к ухудшению точности на 10 % в среднем для выбранных данных и моделей классификации.

Далее проверка достигаемых качественных показателей полноты (2), точности (3), F-меры (4) выполнялась на последовательностях других датасетов [25, 26]. Определялись подпоследовательности, полученные для различных длин окна и сдвигов, затем, аналогично графикам рис. 4, выбирались максимальные (max), средние (avg) и минимальные (min) значения показателя точности (2). Размер окна варьировался от двух до 50 объектов наблюдения.

Значения качественных показателей (2)–(4) приведены в табл. 3. Значения ранжировались относительно показателя (2). Представленные результаты показывают, что предложенный способ формирования и выбора подпоследовательностей оказывает влияние на результаты обработки последовательностей рассмотренными классифицирующими алгоритмами. Применяя описанный способ формирования подпоследовательностей, можно повысить качественный показатель относительно «средних» показателей на 10 %, а относительно «худших» — до 30 %.

Эксперимент показывает важность формирования обучающих примеров для повышения качества обработки данных. Необходимо анализировать возможность формирования подпоследовательностей, имеющих свойства данных, на которых классифицирующие алгоритмы могут достигать более высоких качественных показателей обработки. Применение метода автоматического формирования подпоследовательностей и последующий анализ показателей качества использующих их моделей дает возможность локализовывать группы объектов наблюдения и нивелировать влияние различных эффектов, связанных с шумовыми данными и выбросами.

Однако основным ограничением предложенного метода, как и большого количества методов машинного обучения, по-прежнему остается «проблема малых данных». При применении предлагаемого решения необходимо, чтобы данные повторяли свойства генеральной совокупности для формирования адекватной модели обработки.

Оценка потенциальных качественных показателей при обучении моделей на подпоследовательностях дает возможность определить алгоритм обработки, обладающий лучшими показателями функционала качества.

■ Таблица 3. Результаты классифицирующих алгоритмов

■ Table 3. Results of classifying algorithms

Модель	Значение	Drone RF dataset			PJM Hourly Energy Consumption Data			Electricity Load Diagrams 2011–2014		
		Pr	Rec	F1	Pr	Rec	F1	Pr	Rec	F1
NB	min	54,7	73,0	62,5	35,0	74,4	47,6	50,7	23,6	32,2
	avr	75,8	76,2	76,0	65,9	74,4	69,9	68,1	39,2	49,8
	max	79,1	77,1	78,1	75,0	68,5	71,6	70,0	51,4	59,3
LD	min	63,7	75,9	69,3	58,9	67,7	63,0	70,5	53,6	60,9
	avr	77,4	76,1	76,7	80,0	68,8	74,0	68,4	54,7	60,8
	max	82,2	77,7	79,9	81,0	70,1	75,2	72,6	55,4	62,8
DT	min	61,5	70,4	65,6	39,1	67,3	49,5	45,5	26,9	33,8
	avr	70,9	71,9	71,4	64,0	41,6	50,4	56,9	37,7	45,4
	max	80,7	73,1	76,7	78,6	70,4	74,3	70,5	54,7	61,6
KNN	min	82,8	74,0	78,2	75,6	67,5	71,3	68,5	56,6	62,0
	avr	84,9	76,6	80,5	80,8	70,9	75,5	70,4	60,7	65,2
	max	91,4	78,6	84,5	82,5	72,0	76,9	72,1	59,7	65,3
SVM	min	49,7	68,1	57,5	46,6	61,5	53,0	71,1	22,3	34,0
	avr	77,1	81,7	79,3	67,7	76,3	71,7	53,9	43,7	48,3
	max	79,6	87,1	83,2	74,4	81,4	77,7	61,5	55,8	58,5
ENS	min	83,3	65,8	73,5	80,8	60,8	69,4	45,6	29,7	36,0
	avr	90,5	83,0	86,6	84,7	77,8	81,1	61,1	34,5	44,1
	max	95,4	80,2	87,2	92,3	72,0	80,9	73,1	57,2	64,2

Заключение

Анализ данных и выявление свойств выборок на предварительных этапах разработки моделей машинного обучения может оказывать существенное влияние на результат.

В статье предложен метод формирования подпоследовательностей, использующий анализ показателей качества моделей обработки. В отличие от известных методов, осуществляющих настройку моделей машинного обучения на обрабатываемые данные, в предлагаемом решении выбор способа разделения последовательности на подпоследовательности осуществляется с таким, чтобы свойства полученных в подпоследовательности данных лучшим образом соответствовали модели обработки. Происходит не только настройка модели на выборку данных, а формируются и выбираются подпоследовательности со свойствами данных под модель обработки.

Основное преимущество предлагаемого метода состоит в возможности выбора подпоследовательностей на основе анализа функционала качества модели, что дает возможность определить способы разделения на сегменты, позволяющие повысить показатели качества обработки.

В рассмотренном методе предлагается осуществлять формирование подпоследовательностей из выборки данных, а далее тестировать на них алгоритмы машинного обучения и модели обработки. Критерием выбора является достижение лучшего показателя качества при переборе всех имеющихся вариантов, что дает возможность выбрать лучшую модель.

Предложенный метод позволяет частично преодолевать такие проблемы, как недостаточное количество меток в «малых выборках данных». В результате его применения становится возможным обучать модель с использованием данных, которые маркированы частично или неточно, а также снижать затраты на процесс маркировки.

Предложенный метод в зависимости от решаемой задачи обработки данных методами машинного обучения может применяться как отдельно, так и совместно с другими методами.

Финансовая поддержка

Исследование выполнено за счет гранта Российского научного фонда № 25-21-00269, <https://rscf.ru/project/25-21-00269/>.

Литература

1. Safonova A., Ghazaryan G., Stiller S., Main-Knorn M., Nendel C., Ryo M. Ten deep learning techniques to address small data problems with remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 2023, vol. 125, Article 103569. doi:10.1016/j.jag.2023.103569
2. Lauriola I., Lavelli A., Aiolfi F. An introduction to deep learning in Natural Language Processing: Models, techniques, and tools. *Neurocomputing*, 2022, vol. 470, pp. 443–456. doi:10.1016/j.neucom.2021.05.103
3. AL-Ghuri A., Nazri M., Yaakub M., Alyasseri Z. Multi-objective unsupervised feature selection and cluster based on symbiotic organism search. *Algorithms*, 2024, vol. 17, no. 8, Article 355. doi:10.3390/a17080355
4. Bennaceur H., Almutairy M., Alhussain N. Genetic algorithm combined with the K-Means algorithm: A hybrid technique for unsupervised feature selection. *Intelligent Automation and Soft Computing*, 2023, vol. 37, pp. 2687–2706.
5. Marques H. O., Swersky L., Sander J., Campello R., Zimek A. On the evaluation of outlier detection and one-class classification: A comparative study of algorithms, model selection, and ensembles. *Data Mining and Knowledge Discovery*, 2023, vol. 37, no. 4, pp. 1473–1517.
6. Rinaldo A., Wang D., Wen Q., Willett R. Localizing changes in highdimensional regression models. *The 24th International Conference on Artificial Intelligence and Statistics*, April 13–15, 2021, pp. 2089–2097.
7. Huang J., Chen P., Lu L., Deng Y., Zou Q. WCDForest: A weighted cascade deep forest model toward the classification tasks. *Applied Intelligence*, 2023, vol. 53, no. 23, pp. 1–14.
8. Ammar M., Rania K. A comprehensive review on ensemble deep learning: Opportunities and challenges. *Journal of King Saud University – Computer and Information Sciences*, 2023, vol. 35, iss. 2, pp. 757–774. doi:10.1016/j.jksuci.2023.01.014
9. Lebedev I. S., Sukhoparov M. E. Improving the quality indicators of multilevel data sampling processing models based on unsupervised clustering. *Emerging Science Journal*, 2024, vol. 8, no. 1, pp. 355–371. doi:10.28991/ESJ-2024-08-01-025
10. Rahul P., Robert D. Nowak. Banach space representer theorems for neural networks and ridge splines. *Journal of Machine Learning Research*, 2021, vol. 22, pp. 1–40.
11. Xu S., Song Y., Hao X. A Comparative study of shallow machine learning models and deep learning models for landslide susceptibility assessment based on imbalanced data. *Forests*, 2022, vol. 13, no. 11, pp. 1908–1930. https://doi.org/10.3390/f13111908
12. Li Y., Guo X., Lin W., Zhong M., Li Q., Liu Z., Zhong W., Zhu Z. Learning dynamic user interest sequence in knowledge graphs for click-through rate prediction. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 1, pp. 647–657. doi:10.1109/TKDE.2021.3073717
13. Tong W., Wang Y., Liu D. An adaptive clustering algorithm based on local-density peaks for imbalanced data without parameters. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 4, pp. 3419–3432. doi:10.1109/TKDE.2021.3138962
14. Qiao Q., Yunusa-Kaltungo A., Rodger E. Feature selection strategy for machine learning methods in building energy consumption prediction. *Energy Reports*, 2022, vol. 8, pp. 13621–13654. https://doi.org/10.1016/j.egyr.2022.10.125
15. Лебедев И. С. Сегментирование множества данных с учетом информации воздействующих факторов. *Информационно-управляющие системы*, 2021, № 3, с. 29–38. doi:10.31799/1684-8853-2021-3-29-38
16. Wang P., Xue B., Liang J., Zhang M. Feature clustering-Assisted feature selection with differential evolution. *Pattern Recognition*, 2023, vol. 140, Article 109523. doi:10.1016/j.patcog.2023.109523
17. Зегжда Д. П., Калинин М. О., Крундышев В. М., Лаврова Д. С., Москвин Д. А., Павленко Е. Ю. Применение алгоритмов биоинформатики для обнаружения мутирующих кибератак. *Информатика и автоматизация*, 2021, т. 20, № 4, с. 820–844. doi:10.15622/ia.20.4.3, EDN: YNFARR
18. Jin H., Yin G., Yuan B., Jiang F. Bayesian hierarchical model for change point detection in multivariate sequences. *Technometrics*, 2022, vol. 64, no. 2, pp. 177–186.
19. Nevendra M., Singh P. Software defect prediction using deep learning. *Acta Polytechnica Hungarica*, 2021, vol. 18, no. 10, pp. 173–189.
20. Tallman E., West M. Bayesian predictive decision synthesis. *Journal of the Royal Statistical Society. Series B. Statistical Methodology*, 2024, vol. 86, iss. 2, pp. 340–363. https://doi.org/10.1093/jrssb/qkad109
21. Xiao Z., Xing H., Zhao B., Qu R. Deep contrastive representation learning with self-distillation. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, vol. 8, no. 1, pp. 3–15. doi:10.1109/TETCI.2023.3304948
22. Xiao Z., Xing H., Qu R., Feng L., Luo S., Dai P., Zhao B., Dai Y. Densely knowledge-aware network for multivariate time series classification. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2024, vol. 54, no. 4, pp. 2192–2204. doi:10.1109/TSMC.2023.3342640
23. Barzegar V., Laflamme S., Hu C., Dodson J. Multi-time resolution ensemble lstms for enhanced feature extraction in high-rate time series. *Sensors*, 2021, vol. 21, Article 1954. doi:10.3390/s21061954
24. Лебедев И. С. Адаптивное построение регрессионных моделей на основе анализа функционала качества обработки сегментов последовательно-

сти. *Информатика и автоматизация*, 2025, т. 24, № 2, с. 363–394. doi:10.15622/ia.24.2

25. Lebedev I. S., Sukhoparov M. E. Adaptive learning and integrated use of information flow forecasting methods. *Emerging Science Journal*, 2023, vol. 7, no. 3, pp. 704–723. doi:10.28991/ESJ-2023-07-03-03
26. Allahham M., Al-Sa'd M. F., Al-Ali A., Amr M., Khattab T., Erbad A. DroneRF dataset: A dataset of

drones for RF-based detection, classification and identification. *Data in Brief*, 2019, vol. 26, Article 104313. doi:10.1016/j.dib.2019.104313

27. Trindade A. Electricity Load Diagrams 2011–2014 [Dataset]. *UCI Machine Learning Repository*, 2015. doi:10.24432/C58C86. <https://archive.ics.uci.edu/dataset/321/electricityloadaddiagrams20112014> (дата обращения: 05.08.2024).

UDC 621.396

doi:10.31799/1684-8853-2025-3-25-36

EDN: SSGKZU

Sequential information processing using adaptive pattern analysis in assessing the state of systems

I. S. Lebedev^a, Dr. Sc., Tech., Professor, orcid.org/0000-0001-6753-2181, isl_box@mail.ru

^aSt. Petersburg Federal Research Center of the RAS, 39, 14th Line, 19178, Saint-Petersburg, Russian Federation

Introduction: The formation and labeling of samples is a labor-intensive procedure that plays an important role in the processes of training and tuning many machine learning models. While solving problems using artificial intelligence methods, there is a need to reduce the data labeling complexity. **Purpose:** To improve the quality of information sequence processing using the formation, analysis and determination of sequential segments, with the best quality indicators achieved by predetermined machine learning algorithms. **Results:** We propose a method for forming information sequence segments based on the analysis of processing model quality indicators. It differs from the existing methods that tune machine learning models to process data, by dividing the sequence into segments and choosing a segmentation method so that the properties of the data obtained in the segment could best match the processing model. In contrast to the classical approach where the model is tuned to the data, in the proposed method the data is adjusted to the model by segmenting the sequence. **Practical relevance:** The results can be used for the models and methods which solve the problems of information sequence classification and forecasting. The proposed method makes it possible to partially overcome several problematic issues by labeling small data samples. As a result, it becomes possible to train models using the data that is partially or inaccurately labeled, and to reduce the labeling process complexity. The further development of the proposed solution is possible based on ensemble methods.

Keywords — machine learning, adaptive models, quality improvement, adaptive sequence processing.

Financial support

This research is supported by Russian Science Foundation, grant No. 25-21-00269, <https://rscf.ru/project/25-21-00269/>.

For citation: Lebedev I. S. Sequential information processing using adaptive pattern analysis in assessing the state of systems. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 25–36 (In Russian). doi:10.31799/1684-8853-2025-3-25-36, EDN: SSGKZU

Reference

1. Safonova A., Ghazaryan G., Stiller S., Main-Knorn M., Nendel C., Ryo M. Ten deep learning techniques to address small data problems with remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 2023, vol. 125, Article 103569. doi:10.1016/j.jag.2023.103569
2. Lauriola I., Lavelli A., Aioli F. An introduction to deep learning in Natural Language Processing: Models, techniques, and tools. *Neurocomputing*, 2022, vol. 470, pp. 443–456. doi:10.1016/j.neucom.2021.05.103
3. AL-Gburi A., Nazri M., Yaakub M., Alyasseri Z. Multi-objective unsupervised feature selection and cluster based on symbiotic organism search. *Algorithms*, 2024, vol. 17, no. 8, Article 355. doi:10.3390/a17080355
4. Bennaceur H., Almutairy M., Alhussain N. Genetic algorithm combined with the K-Means algorithm: A hybrid technique for unsupervised feature selection. *Intelligent Automation and Soft Computing*, 2023, vol. 37, pp. 2687–2706.
5. Marques H. O., Swersky L., Sander J., Campello R., Zimek A. On the evaluation of outlier detection and one-class classification: A comparative study of algorithms, model selection, and ensembles. *Data Mining and Knowledge Discovery*, 2023, vol. 37, no. 4, pp. 1473–1517.
6. Rinaldo A., Wang D., Wen Q., Willett R. Localizing changes in highdimensional regression models. *The 24th International Conference on Artificial Intelligence and Statistics*, April 13–15, 2021, pp. 2089–2097.
7. Huang J., Chen P., Lu L., Deng Y., Zou Q. WCDForest: A weighted cascade deep forest model toward the classification tasks. *Applied Intelligence*, 2023, vol. 53, no. 23, pp. 1–14.
8. Ammar M., Rania K. A comprehensive review on ensemble deep learning: Opportunities and challenges. *Journal of King Saud University – Computer and Information Sciences*, 2023, vol. 35, iss. 2, pp. 757–774. doi:10.1016/j.jksuci.2023.01.014
9. Lebedev I. S., Sukhoparov M. E. Improving the quality indicators of multilevel data sampling processing models based on unsupervised clustering. *Emerging Science Journal*, 2024, vol. 8, no. 1, pp. 355–371. doi:10.28991/ESJ-2024-08-01-025
10. Rahul P., Robert D. Nowak. Banach space representer theorems for neural networks and ridge splines. *Journal of Machine Learning Research*, 2021, vol. 22, pp. 1–40.
11. Xu S., Song Y., Hao X. A comparative study of shallow machine learning models and deep learning models for landslide susceptibility assessment based on imbalanced data. *Forests*, 2022, vol. 13, no. 11, pp. 1908–1930. <https://doi.org/10.3390/f13111908>
12. Li Y., Guo X., Lin W., Zhong M., Li Q., Liu Z., Zhong W., Zhu Z. Learning dynamic user interest sequence in knowledge graphs for click-through rate prediction. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 1, pp. 647–657. doi:10.1109/TKDE.2021.3073717
13. Tong W., Wang Y., Liu D. An adaptive clustering algorithm based on local-density peaks for imbalanced data without parameters. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 4, pp. 3419–3432. doi:10.1109/TKDE.2021.3138962
14. Qiao Q., Yunusa-Kaltungo A., Rodger E. Feature selection strategy for machine learning methods in building energy

- consumption prediction. *Energy Reports*, 2022, vol. 8, pp. 13621–13654. <https://doi.org/10.1016/j.egyr.2022.10.125>
15. Lebedev I. S. Dataset segmentation considering the information about impact factors. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2021, no. 3, pp. 29–38 (In Russian). doi:10.31799/1684-8853-2021-3-29-38
 16. Wang P., Xue B., Liang J., Zhang M. Feature clustering-Assisted feature selection with differential evolution. *Pattern Recognition*, 2023, vol. 140, Article 109523. doi:10.1016/j.patcog.2023.109523
 17. Zegzhda D., Kalinin M., Krundyshev V., Lavrova D., Moskvina D., Pavlenko E. Application of bioinformatics algorithms for polymorphic cyberattacks detection. *Informatics and Automation* (SPIRAS Proc.), 2021, vol. 20, no. 4, pp. 820–844 (In Russian). doi:10.15622/ia.20.4.3, EDN: YNFARR
 18. Jin H., Yin G., Yuan B., Jiang F. Bayesian hierarchical model for change point detection in multivariate sequences. *Technometrics*, 2022, vol. 64, no. 2, pp. 177–186.
 19. Nevendra M., Singh P. Software defect prediction using deep learning. *Acta Polytechnica Hungarica*, 2021, vol. 18, no. 10, pp. 173–189.
 20. Tallman E., West M. Bayesian predictive decision synthesis. *Journal of the Royal Statistical Society. Series B. Statistical Methodology*, 2024, vol. 86, iss. 2, pp. 340–363. <https://doi.org/10.1093/jrsssb/qkad109>
 21. Xiao Z., Xing H., Zhao B., Qu R. Deep contrastive representation learning with self-distillation. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, vol. 8, no. 1, pp. 3–15. doi:10.1109/TETCI.2023.3304948
 22. Xiao Z., Xing H., Qu R., Feng L., Luo S., Dai P., Zhao B., Dai Y. Densely knowledge-aware network for multivariate time series classification. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2024, vol. 54, no. 4, pp. 2192–2204. doi:10.1109/TSMC.2023.3342640
 23. Barzegar V., Laflamme S., Hu C., Dodson J. Multi-time resolution ensemble lstms for enhanced feature extraction in high-rate time series. *Sensors*, 2021, vol. 21, Article 1954. doi:10.3390/s21061954
 24. Lebedev I. S. Adaptive regression model construction based on the functional quality analysis of the sequence segment processing. *Informatics and Automation*, 2025, vol. 24, no. 2, pp. 363–394 (In Russian). doi:10.15622/ia.24.2
 25. Lebedev I. S., Sukhoparov M. E. Adaptive learning and integrated use of information flow forecasting methods. *Emerging Science Journal*, 2023, vol. 7, no. 3, pp. 704–723.
 26. Allahham M., Al-Sa'd M. F., Al-Ali A., Amr M., Khattab T., Erbad A. DroneRF dataset: A dataset of drones for RF-based detection, classification and identification. *Data in Brief*, 2019, vol. 26, Article 104313. doi:10.1016/j.dib.2019.104313
 27. Trindade A. Electricity Load Diagrams 2011-2014 [Dataset]. *UCI Machine Learning Repository*, 2015. doi:10.24432/C58C86. Available at: <https://archive.ics.uci.edu/dataset/321/electricityloadaddiagrams20112014> (accessed 5 August 2024).

УВАЖАЕМЫЕ АВТОРЫ!

Научная электронная библиотека (НЭБ) продолжает работу по реализации проекта SCIENCE INDEX. После того как Вы зарегистрируетесь на сайте НЭБ (<http://elibrary.ru/defaultx.asp>), будет создана Ваша личная страничка, содержание которой составят не только Ваши персональные данные, но и перечень всех Ваших печатных трудов, имеющих в базе данных НЭБ, включая диссертации, патенты и тезисы к конференциям, а также сравнительные индексы цитирования: РИНЦ (Российский индекс научного цитирования), h (индекс Хирша) от Web of Science и h от Scopus. После создания базового варианта Вашей персональной страницы Вы получите код доступа, который позволит Вам редактировать информацию, помогая создавать максимально объективную картину Вашей научной активности и цитирования Ваших трудов.



Математическая модель поисковой сенсорной сети с управлением связностью

А. И. Миков^а, доктор физ.-мат. наук, профессор, orcid.org/0009-0001-1469-6198, alexander_mikov@mail.ru

А. А. Миков^а, преподаватель, orcid.org/0009-0007-1552-237X

^аКубанский государственный университет, Ставропольская ул., 149, Краснодар, 350040, РФ

Введение: эффективность применения мобильных сенсорных сетей для решения задач поиска и описания особых областей на поверхности Земли, содержащих краткосрочно наблюдаемые объекты заданного типа, в значительной степени зависит от динамики топологических свойств сетей. Потеря связности сети при перемещении узлов и разбиение ее на компоненты приводит к устареванию информации в узлах и, как следствие, к уменьшению точности решения задач. **Цель:** разработать математическую модель поисковой сенсорной сети и на ее основе – алгоритмы управления связностью мобильной сети, обеспечивающие повышение эффективности поиска. **Результаты:** разработана математическая модель мобильной беспроводной компьютерной сети, использующая модель мобильности в форме случайных блужданий сенсорных узлов для поиска неизвестной области концентрации объектов заданного типа. Скорость поиска оценивается мерой выпуклой оболочки найденного к заданному моменту времени подмножества объектов. Показано, что эффективность процесса поиска определяется взаимодействием двух независимых альтернирующих случайных процессов – изменений состояний объектов «доступен для наблюдения»/«недоступен для наблюдения» и изменений состояний графа компьютерной сети «связан»/«несвязан». Найдены зависимости времени поиска от параметров этих процессов. Сформулированы условия успешного поиска всех объектов. Показано, что одной из основных проблем ускорения поиска является обеспечение связности сети. Разработаны новые алгоритмы управления топологией сенсорных сетей, высокая эффективность которых подтверждена результатами стохастического моделирования. **Практическая значимость:** результаты могут быть применены для создания ad hoc сетей поиска таких областей, как ареалы распространения различных видов животных, районы техногенных и природных катастроф, сосредоточения объектов различных типов.

Ключевые слова — децентрализованный поиск, сенсор узла сети, область обзора, альтернирующий случайный процесс, период невидимости, случайное блуждание, вероятность связности, сближение компонент.

Для цитирования: Миков А. И., Миков А. А. Математическая модель поисковой сенсорной сети с управлением связностью. *Информационно-управляющие системы*, 2025, № 3, с. 37–48. doi:10.31799/1684-8853-2025-3-37-48, EDN: RBIVJOJ

For citation: Mikov A. I., Mikov A. A. Mathematical model of a search sensor network with connectivity control. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 37–48 (In Russian). doi:10.31799/1684-8853-2025-3-37-48, EDN: RBIVJOJ

Введение

Поиск объектов на местности — проблема, часто встречающаяся как в задачах исследовательского, изыскательского характера (установление ареала определенного вида животных или растений), так и в задачах, требующих быстрого нахождения решения (определение границ разлива нефтепродуктов, поиск очагов возгорания при масштабных пожарах).

Одним из способов решения таких задач могут быть децентрализованные мобильные компьютерные сенсорные сети [1], так как они могут применяться в совершенно различных средах (в воздухе [2], под водой [3], на поверхности Земли [4, 5]) с учетом разных топологий местностей (например, городских застроек), в транспортных сетях [6, 7], при наличии препятствий для движения узлов и распространения сигналов [8], в том числе в трехмерных средах [9].

Одной из главных проблем работы мобильных ad hoc сетей является потеря связности се-

ти. Из-за перемещения узлов расстояния между ними могут увеличиваться, что ведет к снижению соотношения сигнал/шум при беспроводной передаче данных [10].

Если сеть связна, то быстрый обмен данными обеспечивает каждый узел актуальной информацией о состоянии сети и ее расположении. Однако условия функционирования мобильных сетей сопряжены с постоянной потерей связности в течение всего времени работы. Поэтому такие приложения проектируются как толерантные к задержкам.

Если сеть перестает быть связной, т. е. делится на несколько компонент связности, то каждая из них в отдельности может оперировать только устаревшей информацией, так как перестает получать обновления от других компонент. Это в свою очередь ведет к снижению точности результатов поиска.

Когда связность восстанавливается, узлы вновь могут быстро обмениваться данными и актуализировать информацию. В общем случае

количество и состав компонент могут быть различными, поэтому возраст информации в отдельных узлах также будет отличаться.

Параметры мобильности [11] узлов могут в известных пределах изменяться управляющими агентами. На основе определенных свойств графового представления сети, например наличия точек сочленения, мостов, блоков, можно предсказать вероятное ухудшение показателей связности и производить соответствующее управляющее воздействие, уменьшая в итоге средний возраст информации в мобильной сенсорной сети. Изменение возраста информации в узлах сети — это случайный многомерный процесс. Изучение этого процесса позволяет оценить глобальные характеристики качества обслуживания мобильной сети, а также усовершенствовать методы самоуправления агентов в узлах.

Среди основных аспектов данного исследования выделим анализ процессов старения информации в мобильной сенсорной сети для задачи поиска области. Также изучаются возможности управляемого изменения топологии сети для улучшения характеристик качества обслуживания. В результате улучшений средний возраст информации в сети уменьшается.

Одним из инструментов анализа являются модели мобильности узлов в динамических случайных графах [11].

Во многих работах [12–14] затрагивается проблема совместного проектирования радиоподсистемы и подсистемы наблюдения. Если они проектируются независимо, то могут получаться результаты, не применимые к системе, в которой они работают совместно. Акцент на алгоритмах оптимизации в задачах покрытия определенной области сделан в [15]. В [16–18] отмечается, что приложения реального времени, решающие эти задачи, могут выполняться в мобильных сетях, не обладающих постоянной связностью, в оппортунистических сетях.

Важность обмена информацией агентов, находящихся в разных узлах сети, подчеркивается в работе [19]. В [20] проведен анализ связности сети с учетом геометрического подхода.

Модели сенсорной сети и искомой области

Пусть *Region* — некоторая ограниченная область (на поверхности, в пространстве), внутри которой находятся все элементы описываемой ниже модели. Назовем ее *областью поиска*.

Сенсоры узлов сети имеют возможность обнаруживать в *Region* объекты некоторого заданного типа и определять их координаты. Однако они не могут фиксировать какие-либо их индивиду-

альные отличия. Задачей сети в целом является отыскание и описание такой выпуклой подобласти $P \subset Region$ минимальной площади, что все обнаруженные объекты (множество точек S) находятся внутри P (включая границу). Требование выпуклости области и ее минимальной площади диктуется практическими соображениями, например удобством и стоимостью последующего постоянного наблюдения за областью или проведения каких-либо операций над областью, а также тем фактом, что случайно обнаруженные во время поиска объекты не исчерпывают все множество возможных объектов, находящихся в области P .

Для решения задачи устанавливается максимально допустимое время TS , в течение которого она должна быть решена. Это ограничение определяется либо природой самой области и ее объектов, либо интенсивностью расхода энергии аккумуляторов мобильными узлами. Задача считается решенной, если все узлы сенсорной сети обладают одинаковым описанием области P и в течение времени $TS/2$ это описание не изменялось. Требование тождественности итоговой информации во всех узлах определяется полной децентрализацией системы поиска, ни один узел которой не выделяется как точка сбора всех данных.

Каждый объект в области P находится в любой момент времени в одном из двух состояний: *visible* и *invisible*. В состоянии *visible* объект будет обнаружен сенсором, если он находится в пределах зоны (круга, шара) наблюдения сенсора диаметра d . В состоянии *invisible* объект «не виден» сенсору. Объекты характеризуются их позициями (координатами). Процесс смены состояний *visible/invisible* является альтернирующим случайным процессом с двумя функциями распределения вероятностей $V(x) = P\{v \leq x\}$ и $I(x) = P\{i \leq x\}$, где v — длительность периода видимости и i — длительность периода невидимости. Длительности периодов являются независимыми случайными величинами. Поведение объектов взаимно независимо и представляет собой многомерный случайный процесс. Эта модель отражает, в частности, известный эффект неудачного поиска «находились рядом, но не заметили».

Геометрически реализацию случайного процесса можно представить в некоторой области *Region* t евклидова пространства — времени Et с выделенным измерением — осью времени t , как множество m параллельных оси t прямых Obj , соответствующих m объектам области P . Эти прямые разделены на отрезки, равные длительностям — реализациям v и i .

Математической моделью неуправляемой мобильной сети из n узлов с радиусами r зон дей-

ствия приемопередатчиков (отношение сигнал/шум превышает единицу) является динамический геометрический [10] граф $DynG$. Его также можно представить в пространстве Et совокупностью кривых L . Каждой кривой l_i из множества L соответствует вершина графа. Назовем кривую l_i *траекторией вершины i* графа и обозначим $l_i(t)$ точку на прямой l_i , соответствующую значению t на оси времени. Положим, что все l_i также принадлежат области $Region_t$.

Если $\rho(\cdot, \cdot)$ — метрика в пространстве Et , то определим предикаты $e_{ij}(t) = \{\rho(l_i(t), l_j(t)) < r\}$ для всех пар траекторий как *ребра* графа и, соответственно, получим матрицу $M(t)$, составленную из этих предикатов, как матрицу смежности динамического графа. Эта матрица также может быть представлена в геометрической форме в пространстве Et аналогично объектам поиска как множество прямых, разделенных на отрезки — периоды существования и несуществования ребер.

Матрица $M(t)$ дает возможность вычислить предикат $Connected(t, r, n)$ связности динамического графа и другие характеристики, включая составы связных компонент, зависящие от параметра t . Все указанные области и предикаты рассматриваются при $t \geq 0$. Состояния и положения при $t = 0$ считаются начальными. Соответственно, матрица $M(0)$ является стандартной матрицей смежности неориентированного непомеченного графа — начального графа сети $DynG(0) = G_0$.

Пусть $t_1 < t_2 < t_3 < \dots < t_l < t_{l+1}, \dots$ — последовательность всех точек на луче $[0, t)$, в которых какой-либо из предикатов $e_{ij}(t)$ изменяет свое значение. Ей соответствует последовательность $G_1, G_2, \dots, G_l, \dots$ обыкновенных неориентированных графов — состояний динамического графа $DynG$ на интервалах времени $[t_l, t_{l+1})$. При этом на интервале $[0, t_1)$ сохраняется состояние G_0 . Имеют место неравенства $G_l \neq G_{l-1}$ и $G_l \neq G_{l+1}$. Но то, что соседние графы в последовательности $G_0, G_1, G_2, \dots, G_l$ неизоморфны, не исключает изоморфизма других пар графов.

Таким образом, динамический граф $DynG$ эквивалентен последовательности $\{G_l, [t_l, t_{l+1})\}$ графов и интервалов, которую предпочтительнее использовать в программных системах имитационного моделирования для ряда задач анализа свойств мобильных сетей.

Как и в обыкновенном графе, в динамическом графе вершины могут быть нагружены дополнительными характеристиками. В нашем случае модели мобильной сенсорной сети каждой кривой множества L , соответствующей узлу сети, приписывается вещественное значение d — диаметра зоны обзора сенсора. Таким образом, задача поиска области P связывается с моделью сети

двумя параметрами — областью поиска $Region$ и диаметром d .

С точки зрения анализа передачи информации, полученной от сенсоров, от узла к узлу важно, что в последовательности $G_0, G_1, G_2, \dots, G_l, \dots$ одни графы являются связными (любые два узла соединены некоторым маршрутом), а другие — несвязными (состоящими из более чем одной связной компоненты). Следовательно, можно определить *периоды связности* динамического графа как объединения тех смежных интервалов $[t_i, t_{i+1}]$, в течение которых все состояния G_i — связные графы. Аналогично *периоды несвязности* динамического графа — объединения тех смежных интервалов $[t_j, t_{j+1}]$, в течение которых все состояния G_j — несвязные графы.

Для целей настоящего исследования критически важной характеристикой сети являются длины периодов несвязности, поскольку с ними непосредственно связано устаревание информации, распространяемой в сетях, толерантных к задержкам.

В течение периода связности информация во всех узлах является глобально актуальной за счет быстрого (относительно скорости движения узлов) обмена данными между узлами сети. Как только сеть разделяется на компоненты, актуальность становится локальной (в пределах связных компонент). Данные, имеющиеся в узле сети, о той части области P , которая обзревается сенсорами узлов из другой компоненты, начинают устаревать. Максимально возможный возраст информации равен длительности периода несвязности, по окончании которого глобальная актуальность восстанавливается и возраст обнуляется.

Задача поиска области P , по существу, является стохастической: заранее неизвестен ее размер, расположение внутри области $Region$, количество объектов, располагающихся в области, параметры их активности. Поэтому детерминированный, исчерпывающий поиск не имеет преимуществ перед недетерминированным поиском. Следовательно, модель динамического геометрического графа для решения задачи поиска расширяется до случайного динамического геометрического графа. Введенные выше характеристики рассматриваются как случайные значения, случайные процессы, последовательности, случайные объекты. Длительности периодов несвязности графа также являются случайными величинами.


Таким образом, эффективность процесса поиска определяется взаимодействием двух независимых альтернирующих случайных процессов — изменений состояний объектов *visible / invisible* и изменений состояний графа «связен»/«несвязен».

Распределения вероятностей длительности периода несвязности случайного динамического геометрического графа показаны на рис. 1 при условии, что все кривые из множества L являются траекториями случайного блуждания в соответствии с моделью мобильности сети Random Walk [11]. Принятые параметры мобильности: максимальная скорость узла в относительных единицах равна 0,05; максимальное время прямолинейного движения 100.

Графики объединяет вероятность связности начального графа G_0 , во всех трех случаях равная 0,75 (при уменьшении количества узлов n нужно увеличить радиус r , чтобы сохранить вероятность связности графа). При этом средние значения длительности периодов несвязности увеличиваются (24, 36, 52) с увеличением радиусов (220, 300, 410).

Мобильная сеть в процессе поиска строит образ $Conv(S)$ области P как выпуклую оболочку множества точек S . В момент $t = 0$ все объекты области P невидимы, образ пуст, $Conv(S) = \emptyset$. Затем в соответствии с распределением $I(x)$ у отдельных объектов заканчиваются периоды невидимости, и они становятся доступными для обнаружения их сенсорами. Для того чтобы появилось первое ненулевое значение $|Conv(S)|$, требуется обнаружение $\dim Et$ объектов (трех, не находящихся на одной прямой, для поиска на двумерной поверхности, четырех — в трехмерном пространстве). В частности, площадь случайного треугольника (согласно Wolfram MathWorld) составляет в среднем 11/144 площади области P . Распределение вероятностей времени $\tau_{(3)}$ до возможности построения первого ненулевого образа определяется частным видом закона распределения порядковых статистик:

$$P\{\tau_{(3)} < x\} = \sum_{k \in [3, m]} C(k, m) (I(x))^k (I(x))^{m-k}, \quad (1)$$



■ **Рис. 1.** Распределения вероятностей длительности периодов несвязности

■ **Fig. 1.** Probability distributions of the duration of periods of disconnectedness

где $C(k, m)$ — биномиальные коэффициенты; m — количество объектов.

Если длительности периодов невидимости всех объектов ограничены некоторой константой C , то за время C при достаточно больших r и d будет построена вся область $Conv(S)$. Графики рис. 2 показывают, как быстро это произойдет после момента времени $t = 0$ в двумерном случае при равномерном на $[0, b]$, $b = 200$, распределении вероятностей $I(x)$ для различных множеств объектов ($3 \leq |Obj| \leq 3000$).

Все зависимости разделяются на три группы: с возрастающей производной (до момента $t = b$), с локальным максимумом производной, с убывающей производной. В случае $|Obj| = 3$ график рис. 2 соответствует графику распределения вероятностей (1) при $m = 3$, т. е. распределению максимальной порядковой статистики.


Однако для небольших r и d сеть не успевает обнаружить все объекты в течение первого периода. Для того чтобы объект $ob \in Obj$ был обнаружен хотя бы одним из узлов сети и его координаты были включены в $Conv(S)$, необходимо (и достаточно), чтобы

$$\exists t \in \cup v [\exists u \in N | (\rho(l_u(t), ob) < d/2) \wedge (t < TS)], \quad (2)$$

где u — узел сети N ; d — диаметр зоны обзора его сенсора; $\cup v$ — объединение всех периодов видимости данного объекта ob ; t — один из моментов видимости объекта.

Это условие должно быть выполнено для всех узлов искомой области:

$$\forall ob \in Obj [\exists t \in \cup v [\exists u \in N | (\rho(l_u(t), ob) < d/2) \wedge (t < TS)]]. \quad (3)$$



■ **Рис. 2.** Построение оболочки $Conv(S)$ при различных количествах объектов

■ **Fig. 2.** Construction of the $Conv(S)$ for different numbers of objects

Но этого недостаточно для полного решения задачи поиска: следует добавить условие, определяющее глобальное знание всех узлов об области. Достаточно дополнить (3) условием $Connected(t, r, n) = \text{true}$ («граф сети из n узлов с радиусами зон действия приемопередатчиков, равными r , в момент времени t является связным»).

Возраст информации в узлах сети

Поскольку поиск области в любом случае требует времени, то требование постоянной связности сети является излишне сильным. Достаточно использовать сеть, толерантную к задержкам. Вопрос заключается только в том, как эти задержки влияют на время решения задачи.

В примере (рис. 3) область поиска *Region* изображена квадратом на плоскости, а искомая область P (неизвестная узлам сети) — прямоугольником с пунктирными границами. В некоторый момент времени t_0 сеть N состоит из трех компонент, и только узел $U1$ одной из компонент находится в области P .

Объекты $a, b \in Obj$ попадают в область обзора (ограничена черной окружностью) сенсора этого узла $U1$. Но только объект a (черный треугольник) в момент времени t_0 активен (виден), что изображается сплошной линией на временной диаграмме. Объект b (белый треугольник) невиден (пунктирная линия на диаграмме). Узлы


$U2$ и $U3$ находятся на расстоянии, меньшем r , от узла $U1$, поэтому они попадают в одну компоненту графа с быстрым обменом информацией. В момент времени t_0 также потенциально может быть виден объект c , но он не попадает в зону распознавания ни одного из узлов сети. Остальные узлы сети образуют отдельные компоненты графа, не связанные с узлом $U1$, и не обозревают в момент t_0 никакую часть области P , поэтому хранят только информацию, полученную в предшествующие моменты времени (устаревшую).

За счет взаимодействия процессов активности объектов области P и мобильности узлов сенсорной сети за конечное время всегда может быть получен точный результат поиска. Изменение $Conv(S)$ является итерационным процессом последовательного приближения. Между последовательными изменениями выпуклой оболочки проходит некоторое время, поэтому скорость сходимости измеряется как отношение меры области к величине интервала времени (в условных единицах). Для этого предполагаем, что в пространстве Et для множества $A \subset Et$ определена мера $\mu(A)$ — площадь, объем и пр., ставящая в соответствие множеству неотрицательное вещественное число. Все рассматриваемые далее множества полагаем измеримыми. В иллюстративных примерах для оценки эффективности алгоритмов считаем значение $\mu(P)$ известным, но не используемым самим алгоритмом.

Скорость изменения $Conv(S)$ зависит от нескольких факторов (помимо технических параметров n, r, d , параметров модели мобильности):

- 1) относительной активности объектов $act = M_0 / (M_0 + M_1)$. Здесь M_0 — математическое ожидание случайной величины v ;
- 2) направлений перемещения и скоростей узлов сенсорной сети;
- 3) скорости обновления информации в узлах сети.

Первые два фактора приводят к увеличению скорости на начальном этапе, пока отдельные объекты переходят из пассивного состояния в активное и затем к постепенному (отрицательная экспонента) уменьшению скорости, поскольку увеличивается вероятность того, что вновь обнаруженные объекты находятся внутри уже построенной $Conv(S)$, т. е. не вносят свой вклад в расширение выпуклой оболочки. Скорость поиска области выражается формулой $(1 - \exp(at)) \times \exp(bt - c)$, где $a = -2 \times 10^{-5}$; $b = -5 \times 10^{-6}$; $c = 3$ для случая сети из одного узла, отношения площадей $|P|/|Region| = 0,25$, $d = 2$, $|Obj| = 200$, $act = 0,002$, средней скорости перемещения узла с сенсором, равной 0,5. Скорость поиска достигает максимума при $t = 80\,000$ единиц, а затем монотонно снижается.



■ Рис. 3. Состояния сети и области
■ Fig. 3. Network and area states

Третий фактор определяется старением информации в сети. Хотя при обнаружении сенсором узла какого-либо объекта в базу данных вносятся его локация loc и временная метка $TStamp$, абсолютное значение времени несущественно с практической точки зрения. Поэтому, пока сеть связна, возраст информации об объектах области в любом ее узле мы полагаем равным нулю, поскольку данные являются глобально актуальными на момент времени t . Как только в каком-либо узле сети изменяются локальные данные, то благодаря широкополосному протоколу они становятся достоянием всех узлов практически мгновенно (в масштабах времени мобильности).

Возраст информации в узлах сети вычисляется от момента окончания периода связности графа сети, т. е. с началом периода неопределенности (неполноты информации). Возраст задается матрицей $AgeInf(t)$ из элементов $AI_{ij}(t)$. Значение — возраст информации в узле U_i о данных, находящихся в узле U_j . Если эти узлы находятся в разных компонентах, то обновление базы данных в узле U_j за счет получения информации о новых объектах (обнаруженных сенсором узла U_j или узлов, находящихся с ним в одной компоненте) не может привести к обновлению базы данных в узле U_i . Таким образом, элемент матрицы $AI_{ij}(t) = t - t'$, где t' — момент времени, когда узлы U_i и U_j в последний раз находились в одной компоненте связности. В те моменты, когда U_i и U_j находятся в одной компоненте, значение $AI_{ij}(t) = 0$.

В результате выпуклые оболочки, вычисляющиеся в узлах U_i и U_j , будут различны, $Conv_i(S) \neq Conv_j(S)$, и замедлится в среднем построение общей оболочки. Особенно это важно в случае динамических областей поиска.

Движение узлов мобильной сети непрерывно, но изменения в процессе поиска дискретны как по оси времени, так и по другим координатам пространства E^2 . Изменения в промежуточных результатах поиска могут происходить при следующих видах событий:

- 1) окончаниях периодов невидимости объектов области;
- 2) касании границы зоны обзора сенсора местоположения объекта;
- 3) увеличении компоненты графа сети за счет объединения компонент.

Поэтому изменение достигнутого результата для каждой конкретной реализации процесса поиска может быть изображено графически как кусочно-постоянная функция времени.

Обозначим $Im_i(S, t)$ образ области расположения объектов множества S , имеющийся в узле U_i мобильной сенсорной сети в момент времени t , и $Im(S, t)$ «общеизвестный» образ области для всех узлов. $Im_i(S, t)$ содержит свое подмножество S_i

координат объектов, известное узлу U_i к моменту t с временными метками, построенную по нему $Conv(S_i, t)$ и свою строку $AgeInf_i(t)$ матрицы возраста информации. $Im(S, t)$ содержит информацию последнего обновления по всем узлам.

В момент $t = 0$ все указанные множества пустые. Если произошло событие вида 1 (как результат изменений в области P) и выполнено условие (2) или событие вида 2 (как результат мобильности сети), то к соответствующему множеству S_i добавляется элемент. Вычисляется новое значение $Conv(S_i, t)$. Если произошло событие вида 3, то обновляются строки матрицы $AgeInf_i(t)$. В частности, при восстановлении связности графа обновляется $Im(S, t)$ и матрица $AgeInf(t)$.

Интенсивность поиска можно оценить соотношением величины $q(t) = \mu(Conv(S, t)) / \mu(Conv(S))$ и времени, затраченного мобильной сетью на достижение этой величины.


Рассмотрим влияние различных сетевых параметров на интенсивность поиска (рис. 4, а–в).

Здесь и далее в иллюстрациях $Region$ — квадратная область со стороной 10^3 условных единиц длины, область P — прямоугольная 300×200 условных единиц длины, количество узлов $n = 40$, параметры Random Walk: максимальная скорость узлов сети 0,05, максимальное время движения узла по прямой 100 условных единиц времени. Использование условных единиц позволило получить масштабируемые результаты. Приведенные на рисунках зависимости можно интерпретировать для различных реальных условий передвижения узлов поисковой сети — как для больших областей и высокоскоростного движения, так и для относительно малых областей при поиске без использования транспортных средств.

Кривые на рис. 4, а характеризуют сенсорные сети с одинаковыми параметрами ($M_0 = 10$ и $M_1 = 100$, $d = 200$) за исключением величин радиусов r уверенного приема/передачи сигналов. От величин этих радиусов зависят вероятности связности случайных геометрических графов и, следовательно, время, требующееся для обмена данными между узлами. При $r = 200$ вероятность связности довольно мала, что приводит к обнаружению в среднем менее 10 % области на начальном этапе поиска. В то же время при $r = 250$ найденная часть области составляет 50 %.

Такое значительное (в пять раз) соотношение результатов поиска при небольшом изменении одного из главных параметров связности (радиуса r) говорит о том, что устаревание информации вносит очень большой вклад в замедление поиска.

При постоянном $r = 220$ (рис. 4, б) изменение в довольно широких пределах величины d зоны наблюдения сенсора оказывает довольно малое



■ **Рис. 4.** Влияние радиуса r (а), величины d зоны наблюдения (б), периода невидимости (в) на достижение результата поиска

■ **Fig. 4.** The influence of the radius r (а), of the observation zone (б), of the invisibility period (в) on achieving the search result

влияние на величину найденной части области при одинаковых временах поиска, что контрастирует с зависимостями на рис. 4, а.

Для графиков рис. 4, в фиксированы параметры $r = 200$, $d = 400$, $M_0 = 10$, но представлены разные варианты длительностей периодов пассивности ($M_1 = 50, 100, 200, 400$) объектов области P .

Анализ зависимостей рис. 4 показывает, что наибольшим потенциалом повышения эффек-

тивности поиска области в описанной модели является улучшение характеристик связности сети.

Алгоритмы управления топологией сенсорной сети

В неуправляемой сети узлы движутся по независимым траекториям. Поскольку расположение и размеры искомой области P неизвестны, то нет объективных причин выбирать какие-то специальные траектории. Однако ускорить поиск возможно, если уменьшить устаревание информации в узлах, получаемой в процессе поиска. Источником повышения актуальности данных является улучшение характеристик связности графа сети: уменьшение математического ожидания количества связанных компонент, удлинение периодов связности наряду с уменьшением длительности периодов несвязности графа мобильной сети.

Управление топологией сети в задаче пространственного поиска производится в условиях противоречия. С одной стороны, для ускорения поиска необходимо наиболее полное покрытие области *Region* сенсорами узлов мобильной сети, заключающееся в наибольшем распараллеливании работы: зоны обзора должны иметь минимальные пересечения между собой в любой момент времени. Следовательно, узлы должны быть удалены друг от друга. С другой стороны, наибольший «запас связности» сети имеет место, когда геометрический граф – полный, т. е. все узлы близко расположены друг к другу.

Для разрешения этого противоречия могут использоваться различные эвристические методы, включая периодическое вычисление вершинной связности графа, оценку длин ребер геометрического графа и др. На основании этого можно прогнозировать ухудшение показателей связности и вносить корректировки в направление и скорость движения узлов.

Ниже предлагаются децентрализованные алгоритмы управления Gravity и ReverseGravity, реализующие различные варианты сближения компонент.

Основные обозначения в алгоритмах:

C – множество компонент связности, образованных узлами сети. C_i – элемент множества C , компонента связности;

p_i – целевая точка для движения узлов компоненты связности;

$trg(C_i) = p_i$ – функция получения целевой точки компоненты связности;

N_i – множество узлов, составляющих компоненту связности C_i ;

n_{ij} — узел множества N_i , запись состоит из идентификатора узла, получаемого функцией $k(n_p)$, координат в пространстве соответствующей размерности, получаемых функцией $Coord(n_{ij})$, и момента фиксации записи, получаемого функцией $t(n_p)$;

$v(n_{ij})$ — функция, получающая направление движения узла, результат представляется в виде вектора размерности пространства. Присвоение нового значения обозначим как $v_{ij} :=$ вектор размерности пространства;

$M_i = mem(n_{ij})$ — «память» узла n_{ij} о положении других узлов сети, где M_i — множество кортежей вида $m_p = n_p$;

$unique(M_i, f(m_p))$ — функция, возвращающая уникальные элементы множества M_i , по аргументу, выбранному функцией $f(m_p)$, применяемой к каждому элементу множества $m_p \in M_i$;

$C(M_i)$ — функция получения множества компонент связности, образуемых записями M_i (связь между записями m_{p1} и m_{p2} существует, они находятся друг от друга на расстоянии меньше радиуса приема-передачи сигнала).

Описанные алгоритмы отличаются механизмом сближения компонент. При этом они имеют общую структуру:

Листинг 1. Общая структура алгоритмов.

1. **for each** $C_i \in C$ **do**
 1. **Рассчитать целевую точку** p_i компоненты C_i ;
 2. Присвоить компоненте C_i целевую точку;
 3. **for each** $n_{ij} \in N_i$ **do**
 1. Получить целевую точку движения, $p_i := trg(C_i)$;
 2. $rt := p_i - n_{ij}$;
 3. $v_{ij} := v(n_{ij})$, $l := u_{\max} / |rt|$;
 4. $v_{ij} := rt * l$;

Последовательно выполняются следующие шаги.

Листинг 2. Алгоритм расчета целевой точки (для алгоритма Gravity).

1. Объединить все кортежи из памяти узлов $M_m := \cup (\forall n_{ij} \in N_i, mem(n_{ij}))$;
2. Выбрать наименее устаревшие позиции узлов $M_1 := unique(argmax(M_m, t(m_p)), k(m_p))$, выбор уникальных по идентификатору записей с максимальным значением по параметру времени t ;
3. Удалить записи об узлах из текущей компоненты $M_f := \forall m_p \in M_1 \forall n_{ij} \in N_i (k(m_p) \neq j)$;
4. Рассчитать компоненты связности $C := C(M_f)$;
5. Выбрать компоненту связности с наибольшим количеством вершин (случайную, если таких несколько) $C_k := \forall C_f \in C \max(|C_f|) \geq |C_i|$. Если текущая компонента является компонентой с наибольшим количеством вершин, то для нее целевая точка не возвращается;
6. Вычислить $p_k := \sum Coord(n_{kj}) / |N_k|$;


Этот алгоритм иллюстрирует рис. 5, а. Здесь узлы компонент C_2 и C_3 по своим базам данных определили, что компонента C_1 имеет наибольшее количество вершин, и в качестве целевой точки для себя рассчитали ее центр.

Последовательно выполняются следующие шаги.

Листинг 3. Алгоритм расчета целевой точки (ReverseGravity).

1. Объединить все кортежи из памяти узлов $M_m := \cup (\forall n_{ij} \in N_i, mem(n_{ij}))$;
2. Выбрать наименее устаревшие позиции узлов $M_1 := unique(argmax(M_m, t(m_p)), k(m_p))$, выбор уникальных по идентификатору записей с максимальным значением по параметру времени t ;
3. Удалить записи об узлах из текущей компоненты $M_f := \forall m_p \in M_1 \forall n_{ij} \in N_i (k(m_p) \neq j)$;
4. Рассчитать компоненты связности $C := C(M_f)$;
5. Выбрать компоненту связности с наименьшим количеством вершин (случайную, если таких несколько) $C_k := \forall C_f \in C \min(|C_f|) \leq |C_i|$. Если текущая компонента является компонентой с наибольшим количеством вершин, то для нее целевая точка не возвращается;
6. Вычислить $p_k := \sum Coord(n_{kj}) / |N_k|$;

Этот алгоритм иллюстрирует рис. 5, б. Здесь узлы компонент C_2 и C_3 по своим базам данных



■ **Рис. 5.** Взаимодействие компонент в алгоритме Gravity (а) и ReverseGravity (б)

■ **Fig. 5.** Interaction of components in the Gravity algorithm (а) and ReverseGravity algorithm (б)

определили, что компонента C_1 имеет наименьшее количество вершин, и в качестве целевой точки для себя рассчитали ее центр, который одновременно является центром единственной вершины компоненты.

В алгоритме Gravity целевой точкой является центр масс наибольшей компоненты связности. В таком случае управляющим воздействием подвергается более разреженная часть графа, что ведет к большей плотности расположения узлов и уменьшению вероятности потери связности. В алгоритме ReverseGravity целевой точкой является центр масс меньшей компоненты связности, часто это отдельный узел. В этом случае вся поисковая сеть будет смещаться в сторону отдельных узлов, приводя постепенно к большей области обзора.

Вычислительная сложность алгоритмов определяется следующими этапами.

Первый этап: объединение памяти узлов. Каждый узел формирует свой массив данных, состоящий из информации о $(n - |N_i|)$ узлах, не принадлежащих компоненте. Затем для каждого узла за время $O(|N_i| * (n - |N_i|))$ отыскивается актуальная информация о позиции, в худшем случае сложность $O(n^2)$.

Второй этап: расчет компонент связности для полученных позиций узлов. Этот этап может производиться с помощью существующих алгоритмов, например алгоритмом Дейкстры, сложность $O(n^2)$.

Третий этап: поиск наибольшей или наименьшей компоненты связности по количеству принадлежащих ей вершин. Оценка для этого этапа $O(|C|)$, где C — множество компонент связности, полученных на предыдущем этапе, или $O(n)$.

Четвертый этап: расчет целевой точки; состоит из расчета центральной точки целевой компоненты, сложность $O(|C_i|)$, и расчета нового направления движения для каждого узла, сложность $O(|N_i|)$. В худшем случае сложность этапа $O(n)$. Этап опционален, поскольку текущая компонента связности может оказаться целевой.

Так как алгоритм выполняется на каждом узле параллельно, а этапы последовательны и не вложены друг в друга, общая вычислительная сложность $O(n^2)$. При этом указанная оценка применима к обоим предложенным алгоритмам.

Оценка эффективности алгоритмов

Для оценки эффективности алгоритмов проведено имитационное моделирование с помощью фреймворка [21].

В области $Region = [0; 1000]^2$ располагалось 40 узлов сенсорной сети со случайными координатами, имеющими двумерное равномерное распределение. В каждой группе экспериментов

задавалась область P размера 500×300 в случайном положении, внутри которой генерировалось множество S случайных точек, обозначающих объекты, $|S| = 300$. Вычислялась мера $\mu(Conv(S))$ для контроля предельного значения величин $\mu(Conv(S, t))$ при $t \rightarrow \infty$. Для каждого объекта задавалось независимое поведение видимости и невидимости с параметрами $M_v = 10$, $M_l = 100$. Имитационный запуск включал в себя вычисление движения узлов сети до некоторого момента t_{max} в соответствии с моделью мобильности Random Walk для сети без управления. Для сетей с управлением эта модель динамически корректировалась алгоритмом Gravity или ReverseGravity. Параллельно вычислялось $q(t) = \mu(Conv(S, t)) / \mu(Conv(S))$. По окончании серии экспериментов вычислялась оценка математического ожидания $Mq(t)$.

Одним из косвенных показателей эффективности алгоритмов управления связностью является количество компонент в графе сети. В таблице для различных значений радиусов r устройств радиосвязи узлов приведены средние значения количества компонент в графах сетей.


Средние значения взяты за период $0 \leq t \leq 100$. Числа показывают, что в отсутствие управления уже при $r < 220$ граф обычно содержит более двух компонент, в то время как при использовании управления он связан приблизительно в течение половины периода наблюдения. При $r = 170$ различие в числе компонент в три раза.

Показаны (рис. 6, а) зависимости $Mq(t)$ для трех случаев: без управления (кривая N), с использованием алгоритма Gravity (кривая G) и с использованием алгоритма ReverseGravity (кривая RG).

Анализ графиков показывает, что начальные скорости поиска (угол наклона касательных в точке $t = 0$) совпадают, но затем начинают проявляться эффекты управления связностью. К моменту времени $t = 100$ поиск с использованием алгоритма Gravity почти закончен ($q(100) > 0,92$), но без управления он не достиг и 2/3 значения $\mu(Conv(S))$. Замедление прогресса — уменьшение производной $Mq(t)$ с течением времени — связано с повышением вероятности

- Среднее количество компонент в графе сети
- Average value of component number

Режим управления	r					
	170	200	220	250	280	300
Без управления	7,0	3,5	2,4	1,5	1,2	1,10
С алгоритмом Gravity	2,3	2,2	1,6	1,2	1,1	1,03



■ **Рис. 6.** Эффективность поиска алгоритмами Gravity и ReverseGravity: *a* – $r = 250, d = 340$; *б* – $r = 200, d = 440$
 ■ **Fig. 6.** Search efficiency of Gravity and ReverseGravity algorithms: *a* – $r = 250, d = 340$; *б* – $r = 200, d = 440$


для каждого нового найденного объекта попасть внутрь увеличивающейся оболочки $Conv(S)$.

По графикам рис. 6, б видно, что произойдет, если уменьшить радиус связи между узлами ($r = 200$), увеличив размер зоны обзора узла (440), в близких пропорциях, по сравнению со значениями рис. 6, а.

Здесь эффект использования предложенных алгоритмов еще более значителен. К моменту времени $t = 100$ сеть без управления связностью в среднем находит около 10 % площади области, в то время как с алгоритмом управления связностью Gravity сеть находит 63 % площади области, а с алгоритмом ReverseGravity – около 57 % области.

Небольшое различие в эффективности алгоритмов управления можно объяснить тем, что в случае алгоритма ReverseGravity при отклонении одного из узлов вся сеть движется в его сторону, в отличие от Gravity, где вся сеть остается на месте, а управляющему воздействию подвергается только отклонившийся узел.

В сенсорных сетях большего размера эффективность управления связностью с помощью алгоритма Gravity также очевидна. На рис. 7



■ **Рис. 7.** Эффективность поиска без управления и с алгоритмом Gravity
 ■ **Fig. 7.** Search efficiency without control and with the Gravity algorithm

приведены зависимости $q(t)$ для больших сетей ($n = 100, r = 150, d = 340$) и сетей с очень высокой плотностью узлов ($n = 300, r = 100, d = 340$).

Вариант $n = 300$ интересен тем, что количество узлов сети равно количеству объектов в искомой области. Наличие управления при такой высокой плотности позволяет найти точное значение выпуклой оболочки области P уже к моменту $t = 360$ ($q(360) = 1$), в то время как без управления величина $q(t)$ в пределах графиков не достигает и 60 % площади области.

Заключение

Описана новая математическая модель децентрализованной мобильной сенсорной сети, решающей задачи поиска случайных объектов переменной видимости и описания области их нахождения в заданной части пространства. В модели учитывается проблема отсутствия связности сети в течение некоторых временных промежутков, которая ведет к устареванию информации, используемой узлами сети для построения описания области. Проведена оценка скорости поиска в зависимости от характеристик объектов и параметров связи узлов и обзора сенсоров. Разработаны алгоритмы управления связностью, выполняемые агентами в узлах сети. Они основаны на динамическом уменьшении количества связных компонент графа сети. В результате работы алгоритмов уменьшается возраст информации в сети, а также в несколько раз ускоряется поиск. Эффективность использования предложенных алгоритмов подтверждена имитационными экспериментами.

Литература

1. Cui Y., Liu F., Jing X., Mu J. Integrating sensing and communications for ubiquitous IoT: Applications, trends and challenges. *IEEE Network*, 2021, vol. 35, no. 5, pp. 158–167. doi:10.1109/MNET.010.2100152
2. Mishra B., Garg D., Narang P., Mishra V. Drone-surveillance for search and rescue in natural disaster. *Computer Communication*, 2020, vol. 156, pp. 1–10.
3. Shermin A., Dhongdi S. C. Review of Underwater Mobile Sensor Network for ocean phenomena monitoring. *Journal of Network and Computer Applications*, 2022, vol. 205, Article 103418. doi:10.1016/j.jnca.2022.103418
4. Hentati A. I., Fourati L. C., Rezgui J. Cooperative UAVs framework for Mobile Target Search and tracking. *Computers and Electrical Engineering*, 2022, vol. 101, Article 107992. doi:10.1016/j.compeleceng.2022.107992
5. Yousuf B., Lendek Z., Buşoni L. Multi-agent exploration-based search for an unknown number of targets. *IFAC-PapersOnLine*, 2023, vol. 56, iss. 2, pp. 5494–5499. doi:10.1016/j.ifacol.2023.10.206
6. Campioni F., Choudhury S., Tariq U., Bashir A. K. Recruitment algorithms for vehicular sensor networks. *Computer Communication*, 2020, vol. 159, pp. 9–14.
7. Sohail M., Latif Z., Javed S., Biswas S., Ajmal S., Iqbal U., Jafri M. R., Khan A. U. Routing protocols in Vehicular Ad hoc Networks (VANETs): A comprehensive survey. *Journal of Internet of Things*, 2023, vol. 23, Article 100837. doi:10.1016/j.iot.2023.100837
8. Phoemphon S., Leelathakul N., So-In C. An enhanced node segmentation and distance estimation scheme with a reduced search space boundary and improved PSO for obstacle-aware wireless sensor network localization. *Journal of Network and Computer Applications*, 2024, vol. 221, Article 103783. doi:10.1016/j.jnca.2023.103783
9. Luo X., Xie J., Xiong L., Liu Y., He Y. Distributed topology control of multiple ISAC-UAVs for mobile search teams in unknown 3-D terrains. *Ad Hoc Networks*, 2025, vol. 169, Article 103753. doi:10.1016/j.adhoc.2025.103753
10. Миков А. И. Информационные процессы и нормативные системы в ИТ: Математические модели. Проблемы проектирования. Новые подходы. М., Либроком, 2020. 256 с.
11. Avena L., GÜltaş H., Hofstad R. van der, Hollander W. T. F. den, Nagy O. Linking the mixing times of random walks on static and dynamic random graphs. *Journal of Stochastic Processes and their Applications*, 2022, vol. 153, pp. 145–182. doi:10.1016/j.spa.2022.07.009
12. Liu F., Yuanhao C., Masouros C., Xu J., Han T. X., Eldar Y., Buzzi S. Integrated sensing and communications: Towards dual-functional wireless networks for 6G and beyond. *IEEE Journal on Selected Areas in Communications*, 2022, vol. 40, no. 6, pp. 1728–1767. doi:10.1109/JSAC.2022.3156632
13. Liu F., Masouros C., Petropulu A., Griffiths H., Hanzo L. Joint radar and communication design: Applications, state-of-the-art, and the road ahead. *IEEE Transactions on Communications*, 2020, vol. 68, no. 6, pp. 3834–3862. doi:10.1109/TCOMM.2020.2973976
14. Azarhava H., Abdollahi M. P., Niya J. M., Tinati M. A. Joint resource allocation and UAV placement in UAV-assisted Wireless Powered Sensor Networks using TDMA and NOMA. *Ad Hoc Networks*, 2024, vol. 157, Article 103459. doi:10.1016/j.adhoc.2024.103459
15. Li Q., Liu N. Monitoring area coverage optimization algorithm based on nodes perceptual mathematical model in wireless sensor networks. *Computer Communication*, 2020, vol. 155, pp. 227–234. doi:10.1016/j.comcom.2019.12.040
16. Миков А. И., Миков А. А. Мультиагентное управление масштабируемыми оппортунистическими сетями. *Информатизация и связь*, 2022, № 1, с. 30–41. doi:10.34219/2078-8320-2022-13-1-30-41
17. Naderi M., Ghanbari M. Adaptively prioritizing candidate forwarding set in opportunistic routing in VANETs. *Ad Hoc Networks*, 2023, vol. 140, Article 103048. doi:10.1016/j.adhoc.2022.103048
18. Sharvari N. P., Das D., Bapat J., Das D. Connectivity and collision constrained opportunistic routing for emergency communication using UAV. *Journal of Computer Networks*, 2023, vol. 220, Article 109468. doi:10.1016/j.comnet.2022.109468
19. Nguyen M. T. Distributed compressive and collaborative sensing data collection in mobile sensor networks. *Internet of Things*, 2020, vol. 9, Article 100156. doi:10.1016/j.iot.2019.100156
20. Habibiyan R., Sabbagh A. G. Connectivity analysis of 2D underwater optical wireless sensor networks using a geometric approach. *Ad Hoc Networks*, 2022, vol. 134, Article 102910. doi:10.1016/j.adhoc.2022.102910
21. Миков А. И., Миков А. А. Анализ мобильных периферийных компьютерных сетей на основе специализированного фреймворка. *Информатизация и связь*, 2023, № 3, с. 7–12. doi:10.34219/2078-8320-2023-14-3-7-12

UDC 519.179.2, 004.722.2

doi:10.31799/1684-8853-2025-3-37-48

EDN: RBIVJOJ

Mathematical model of a search sensor network with connectivity controlA. I. Mikov^a, Dr. Sc., Phys.-Math, Professor, orcid.org/0009-0001-1469-6198, alexander_mikov@mail.ruA. A. Mikov^a, Assistant Professor, orcid.org/0009-0007-1552-237X^aKuban State University, 149, Stavropol St., 350040, Krasnodar, Russian Federation

Introduction: The effectiveness of using mobile sensor networks to solve problems of searching and describing special areas on the Earth's surface containing short-term observable objects of a given type largely depends on the dynamics of the topological properties of the networks. The loss of network connectivity when nodes are moved and its division into components leads to the obsolescence of information in the nodes and, as a result, to a decrease in the accuracy of solving problems. **Purpose:** To develop a mathematical model of a search sensor network and, based on it, algorithms for managing the connectivity of a mobile network that improve search efficiency. **Results:** We develop a mathematical model of a mobile wireless computer network that uses a mobility model in the form of random walks of sensor nodes to search for an unknown area of concentration of objects of a given type. The search speed is estimated by the measure of the convex hull of the subset of objects found by a given time. We demonstrate that the efficiency of the search process is determined by the interaction of two independent alternating random processes: changes in the states of objects "available for observation" / "not available for observation" and changes in the states of the computer network graph "connected" / "disconnected". We find out how the search time depends on the parameters of these processes and formulate the conditions for a successful search for all objects. It has been shown that one of the main problems of speeding up the search is ensuring network connectivity. We develop new algorithms for controlling the topology of sensor networks, the high efficiency of which has been confirmed by the results of stochastic modeling. **Practical relevance:** The results can be applied to create ad hoc search networks for areas such as distribution areas of various animal species, areas of man-made and natural disasters, and concentrations of various types of objects.

Keywords — decentralized search, network node sensor, field of view, alternating random process, period of invisibility, random walk, connectivity probability, component convergence.

For citation: Mikov A. I., Mikov A. A. Mathematical model of a search sensor network with connectivity control. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 37–48 (In Russian). doi:10.31799/1684-8853-2025-3-37-48, EDN: RBIVJOJ

References

1. Cui Y., Liu F., Jing X., Mu J. Integrating sensing and communications for ubiquitous IoT: Applications, trends and challenges. *IEEE Network*, 2021, vol. 35, no. 5, pp. 158–167. doi:10.1109/MNET.010.2100152
2. Mishra B., Garg D., Narang P., Mishra V. Drone-surveillance for search and rescue in natural disaster. *Computer Communication*, 2020, vol. 156, pp. 1–10.
3. Shermin A., Dhongdi S. C. Review of Underwater Mobile Sensor Network for ocean phenomena monitoring. *Journal of Network and Computer Applications*, 2022, vol. 205, Article 103418. doi:10.1016/j.jnca.2022.103418
4. Hentati A. I., Fourati L. C., Rezgui J. Cooperative UAVs framework for Mobile Target Search and tracking. *Computers and Electrical Engineering*, 2022, vol. 101, Article 107992. doi:10.1016/j.compeleceng.2022.107992
5. Yousuf B., Lendek Z., Buşoni L. Multi-agent exploration-based search for an unknown number of targets. *IFAC-PapersOnLine*, 2023, vol. 56, iss. 2, pp. 5494–5499. doi:10.1016/j.ifacol.2023.10.206
6. Campioni F., Choudhury S., Tariq U., Bashir A. K. Recruitment algorithms for vehicular sensor networks. *Computer Communication*, 2020, vol. 159, pp. 9–14.
7. Sohail M., Latif Z., Javed S., Biswas S., Ajmal S., Iqbal U., Jafri M. R., Khan A. U. Routing protocols in Vehicular Ad hoc Networks (VANETs): A comprehensive survey. *Journal of Internet of Things*, 2023, vol. 23, Article 100837. doi:10.1016/j.iot.2023.100837
8. Phoemphon S., Leelathakul N., So-In C. An enhanced node segmentation and distance estimation scheme with a reduced search space boundary and improved PSO for obstacle-aware wireless sensor network localization. *Journal of Network and Computer Applications*, 2024, vol. 221, Article 103783. doi:10.1016/j.jnca.2023.103783
9. Luo X., Xie J., Xiong L., Liu Y., He Y. Distributed topology control of multiple ISAC-UAVs for mobile search teams in unknown 3-D terrains. *Ad Hoc Networks*, 2025, vol. 169, Article 103753. doi:10.1016/j.adhoc.2025.103753
10. Mikov A. I. *Informatsionnye processy i normativnye sistemy v IT: Matematicheskie modeli. Problemy proektirovaniya. Novye podkhody* [Information processes and normative systems in IT: Mathematical models. Design problems. Novel approaches]. Moscow, Librokom Publ., 2020. 256 p. (In Russian).
11. Avena L., Göltaş H., Hofstad R. van der, Hollander W. T. F. den, Nagy O. Linking the mixing times of random walks on static and dynamic random graphs. *Journal of Stochastic Processes and their Applications*, 2022, vol. 153, pp. 145–182. doi:10.1016/j.spa.2022.07.009
12. Liu F., Yuanhao C., Masouros C., Xu J., Han T. X., Eldar Y., Buzzi S. Integrated sensing and communications: Towards dual-functional wireless networks for 6G and beyond. *IEEE Journal on Selected Areas in Communications*, 2022, vol. 40, no. 6, pp. 1728–1767. doi:10.1109/JSAC.2022.3156632
13. Liu F., Masouros C., Petropulu A., Griffiths H., Hanzo L. Joint radar and communication design: Applications, state-of-the-art, and the road ahead. *IEEE Transactions on Communications*, 2020, vol. 68, no. 6, pp. 3834–3862. doi:10.1109/TCOMM.2020.2973976
14. Azarhava H., Abdollahi M. P., Niya J. M., Tinati M. A. Joint resource allocation and UAV placement in UAV-assisted Wireless Powered Sensor Networks using TDMA and NOMA. *Ad Hoc Networks*, 2024, vol. 157, Article 103459. doi:10.1016/j.adhoc.2024.103459
15. Li Q., Liu N. Monitoring area coverage optimization algorithm based on nodes perceptual mathematical model in wireless sensor networks. *Computer Communication*, 2020, vol. 155, pp. 227–234. doi:10.1016/j.comcom.2019.12.040
16. Mikov A. I., Mikov A. A. Multi-agent management of scalable opportunistic networks. *Informatizatsia i svyaz*, 2022, no. 1, pp. 30–41 (In Russian). doi:10.34219/2078-8320-2022-13-1-30-41
17. Naderi M., Ghanbari M. Adaptively prioritizing candidate forwarding set in opportunistic routing in VANETs. *Ad Hoc Networks*, 2023, vol. 140, Article 103048. doi:10.1016/j.adhoc.2022.103048
18. Sharvari N. P., Das D., Bapat J., Das D. Connectivity and collision constrained opportunistic routing for emergency communication using UAV. *Journal of Computer Networks*, 2023, vol. 220, Article 109468. doi:10.1016/j.comnet.2022.109468
19. Nguyen M. T. Distributed compressive and collaborative sensing data collection in mobile sensor networks. *Internet of Things*, 2020, vol. 9, Article 100156. doi:10.1016/j.iot.2019.100156
20. Habibiyan R., Sabbagh A. G. Connectivity analysis of 2D underwater optical wireless sensor networks using a geometric approach. *Ad Hoc Networks*, 2022, vol. 134, Article 102910. doi:10.1016/j.adhoc.2022.102910
21. Mikov A. I., Mikov A. A. Analysis of mobile edge computer networks based on a specialized framework. *Informatizatsia i svyaz*, 2023, no. 3, c. 7–12 (In Russian). doi:10.34219/2078-8320-2023-14-3-7-12



Оптимизация размещения виртуальных объектов в расширенной реальности с использованием динамического программирования

М. В. Алпатова^а, канд. техн. наук, доцент, orcid.org/0000-0003-3018-9601, m.v.alpatova@yandex.ru

Ю. В. Рудяк^б, доктор физ.-мат. наук, профессор, orcid.org/0000-0001-7886-0455

^аМИРЭА – Российский технологический университет, Вернадского пр., 78, Москва, 119454, РФ

^бМосковский политехнический университет, Б. Семеновская ул., 38, Москва, 107023, РФ

Введение: развитие технологий расширенной реальности предъявляет высокие требования к точности размещения виртуальных объектов для обеспечения оптимального пользовательского опыта. В условиях динамично изменяющихся сцен и ограниченных вычислительных ресурсов актуальной остается задача корректной интеграции новых объектов в уже оптимизированную композицию. **Цель:** разработать и экспериментально оценить алгоритм размещения виртуальных объектов в пространстве расширенной реальности с учетом вычислительной эффективности. **Результаты:** предложен модифицированный алгоритм двумерной оптимальной расстановки, основанный на принципах динамического программирования и локальных корректировок. Алгоритм включает предварительную сортировку объектов по размеру, последовательное размещение с минимизацией дисбаланса зон комфортного восприятия и локальный перерасчет позиций, что обеспечивает интеграцию новых элементов без нарушения исходной структуры сцены. Экспериментальная проверка показала, что алгоритм эффективно размещает объекты с учетом их физических размеров и зон комфорта. Временные характеристики демонстрируют линейное увеличение времени выполнения при небольшом количестве объектов (до 35), а при дальнейшем увеличении числа объектов (в диапазоне 35÷70 и выше) наблюдается значительное ускорение темпа роста времени выполнения, особенно на мобильных устройствах. Регрессионный анализ выявил высокую степень корреляции между числом объектов и временем выполнения для персональных компьютеров и устройств iOS, в то время как Android-платформы демонстрируют меньшую масштабируемость. **Практическая значимость:** разработанный метод доказал свою применимость в реальных сценариях расширенной реальности, позволяя снизить вычислительную нагрузку и повысить адаптивность систем расширенной реальности. **Обсуждение:** результаты исследования открывают перспективы дальнейшей оптимизации алгоритма за счет применения параллельных вычислений и аппаратного ускорения, а также расширения его функционала для работы в трехмерных средах.

Ключевые слова — расширенная реальность, виртуальные объекты, оптимальное размещение, динамическое программирование, вычислительная эффективность, буферные зоны, перцептивное состояние, алгоритмы размещения, мобильные устройства, регрессионный анализ.

Для цитирования: Алпатова М. В., Рудяк Ю. В. Оптимизация размещения виртуальных объектов в расширенной реальности с использованием динамического программирования. *Информационно-управляющие системы*, 2025, № 3, с. 49–58. doi:10.31799/1684-8853-2025-3-49-58, EDN: SKBXGY

For citation: Alpatova M. V., Rudyak Y. V. Optimization of virtual object placement in extended reality using dynamic programming. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 49–58 (In Russian). doi:10.31799/1684-8853-2025-3-49-58, EDN: SKBXGY

Введение

Дополненная реальность постоянно развивается с высокой скоростью и используется во многих областях деятельности, начиная от ориентирования на местности и заканчивая педагогикой, от медицины до промышленного дизайна [1, 2]. Сложной задачей для расширенной реальности (Extended Reality, XR) может стать обеспечение точного и естественного размещения виртуальных объектов в пространстве. Отсутствие ориентиров в окружающей среде затрудняет манипуляции пользователя с виртуальными объектами и тем самым ухудшает восприятие и погружение [3]. Ошибки позиционирования могут даже вызывать когнитивный диссонанс, что пагубно сказывается на пользовательском опыте.

Проблема размещения объектов в XR зависит от нескольких факторов, включая точность позиционирования, адаптацию к изменяющимся условиям и удобство восприятия [4, 5]. Такие подходы, как алгоритмы машинного обучения, повышают производительность отслеживания, но требуют больших вычислительных мощностей [6]. В то же время адаптация методов организации пространства способствует более эффективному восприятию XR-контента, но имеет свои ограничения [7]. Исследования также показывают, что факторы окружающей среды, такие как меняющиеся условия освещения и движение объектов, оказывают заметное влияние на точность размещения [3].

В предыдущих исследованиях авторов [5, 8], посвященных размещению объектов в двумер-

ном пространстве с учетом их размеров и «зон комфорта», рассматривались только условия размещения объектов в идеальных случаях изолированного размещения, но не то, как вставить новые объекты в существующую конфигурацию размещения.

Актуальность поиска корректной вставки виртуальных объектов обусловлена необходимостью повышения вычислительной производительности и устойчивости алгоритмов в условиях динамического обновления среды, когда новые объекты должны гармонизировать с уже размещенными в их пространстве объектами, чтобы их позиционирование в пространстве не было нарушено в результате их размещения. Гипотеза исследования заключается в том, что алгоритм, корректно вставляющий новые виртуальные объекты в существующее пространство, значительно повысит производительность и при этом не ухудшит качество размещения в пространстве. Цель данной работы – представить и эмпирически исследовать прагматический подход к размещению виртуальных объектов в существующую конфигурацию XR-пространства оптимальным способом с особым акцентом на тестирование вычислительной производительности алгоритма.

Связь с предыдущими исследованиями

Анализ исследований в области XR подтверждает, что современные подходы обычно сосредоточены на статическом размещении объектов, предотвращении столкновений или динамическом отслеживании. Однако лишь немногие исследования затрагивают проблему оптимального дополнения уже существующей композиции виртуальных объектов. В предыдущем исследовании был представлен алгоритм двумерного размещения, основанный на минимизации целевой функции, который позволял учитывать размеры объектов и окружающие их буферные зоны, обеспечивая равномерное распределение коэффициентов комфортности по всем сторонам каждого объекта [5, 8]. Между тем значительная часть международных исследований посвящена либо эффективному представлению 3D-сцен с использованием многомасштабных воксельных структур, либо динамическому прогнозированию столкновений и оптимизации размещения маркеров с помощью методов глубокого обучения и обучения с подкреплением [9, 10].

Исследования, посвященные структурированию 3D-объектов для XR на смартфонах, демонстрируют высокую вычислительную эффективность, проявляющуюся в ускоренной обработке

данных и оптимальном использовании памяти, что способствует повышению общей производительности мобильных XR-систем. Однако данные подходы не решают задачу интеграции новых объектов в уже созданную композицию с учетом заранее определенных зон комфорта, что остается актуальной проблемой для обеспечения качественного пользовательского опыта [11]. Аналогично исследования мультимодальных методов предсказания столкновений и механизмов самоанализа направлены в первую очередь на обеспечение безопасности взаимодействия объектов в динамических средах, но не учитывают гармоничную интеграцию объектов в предварительно оптимизированное виртуальное пространство [6].

Методы оптимизации размещения, основанные на концепции виртуальных осей и нелинейном программировании, позволяют автоматически определять доступные промежуточные позиции объектов, что крайне важно при формировании композиции. Однако их применение в основном ограничено статическими сценариями [12]. Недавние исследования, использующие глубокое обучение и обучение с подкреплением для динамической корректировки позы, демонстрируют высокую адаптивность к изменениям сцены. Тем не менее эти подходы в первую очередь направлены на обеспечение безопасности и повышение информативности, а не на доработку уже структурированной среды для повышения эффективности вычислений [1, 13].

Таким образом, в настоящее время существует заметное несоответствие между имеющимися способами и методами добавления новых объектов в предварительно оптимизированную композицию с сохранением баланса в комфортных пространствах. В данной статье представлен алгоритм, который не только учитывает физические размеры объектов и их комфортные пространства, но и вставляет их в существующую композицию в оптимальных позициях. В настоящей работе представлен принцип, сочетающий статические методы оптимизации с механизмами адаптации для решения проблемы размещения объектов в XR-пространствах при сохранении высокой производительности системы и качества пользовательского опыта [14, 7, 15].

Постановка задачи и математическая модель

Задачи оптимального размещения объектов широко изучаются в области упаковки (Packing Problem), где разрабатываются эвристические и динамические методы минимизации занимаемой площади и предотвращения пересечений.

Эффективные алгоритмы включают возможность вращения объектов и учитывают ограничения пространства [16]. Вместе с тем для работы в реальном времени критично учитывать динамическое добавление новых объектов, что требует локального пересчета лишь ближайших элементов сцены. Подходы, использующие пошаговую оптимизацию позиций компонентов в ограниченном пространстве, демонстрируют высокую эффективность динамического размещения [17]. Эти принципы подтверждают выбор предложенной стратегии оптимизации сцены в XR, позволяя минимизировать изменения в уже размещенной конфигурации. Рассматриваемый далее подход основывается на ранее предложенном методе, детализированном в работе «Оптимальная 2D расстановка виртуальных объектов в физическом пространстве в приложениях дополненной реальности» [8]. В этом методе основное внимание уделяется последовательному заполнению плоскости с минимизацией разрывов между объектами и обеспечением перцептивной комфортности. Указанный подход включает несколько ключевых этапов, каждый из которых вносит вклад в общий процесс размещения.

Рассматривается задача размещения виртуальных объектов на двумерной плоскости, на которой уже присутствуют ранее установленные элементы. Эти объекты представляют собой набор прямоугольных областей, каждая из которых описывается собственными размерами — шириной w_i и высотой h_i , а также буферными зонами D_i^- , D_i^+ , Z_i^- , Z_i^+ . Буферные зоны служат для поддержания комфортного перцептивного состояния и определяют минимально допустимые расстояния от объекта до соседей или границ доступного пространства.

Плоскость, на которой происходит размещение, имеет фиксированные размеры W по горизонтали и H по вертикали. Объекты должны удовлетворять ограничению нахождения внутри этих границ:

$$\begin{aligned} x_i - D_i^- &\geq 0, \quad x_i + w_i + D_i^+ \leq W; \\ y_i - Z_i^- &\geq 0, \quad y_i + h_i + Z_i^+ \leq H. \end{aligned} \quad (1)$$

Кроме того, допускается, чтобы буферные зоны объектов пересекались, если это позволяет минимизировать целевую функцию перцептивного состояния. Для каждого объекта вводится понятие односторонней комфортности K^- и K^+ , которая рассчитывается на основании расстояний до соседей или границ. Если буферные зоны двух объектов пересекаются, разница в комфортности учитывается в совокупной целевой функции сцены:

$$K_{\Sigma} = \sum_{i=1}^n (K_i^- - K_i^+)^2, \quad (2)$$

где K_i^- и K_i^+ рассчитываются для каждой стороны объекта с использованием буферных расстояний и текущих позиций.

Для гарантии вычислительной эффективности алгоритма ограничивается общий объем перерасчетов. Это достигается путем локализации операций внутри партий объектов, которые формируются динамически, и учета только тех областей пространства, которые непосредственно затрагиваются добавлением новых объектов. Таким образом, каждая итерация перерасчетов минимизирует изменения в положении уже установленных элементов.

Базовый алгоритм размещения

Перед началом размещения объекты сортируются по убыванию их длины h_i . Такая сортировка позволяет первым размещать объекты с максимальными размерами, минимизируя их возможные конфликты с соседями. Формально это условие можно выразить как упорядочение множества объектов N :

$$N' = \{n_1, n_2, \dots, n_k\}, \text{ где } h_i \geq h_{i+1} \text{ для всех } i. \quad (3)$$

Для упорядочения объектов на плоскости используется стратегия челночного хода. На первом этапе объекты располагаются слева направо, начиная от нижнего левого угла плоскости. После достижения правой границы направление меняется на противоположное, и следующая строка заполняется справа налево. Этот метод помогает снизить избыточные смещения между объектами в разных строках и способствует более плотному заполнению плоскости.

Оптимальное положение каждого объекта в строке определяется из условия минимума целевой функции (4). Целевая функция оптимизации минимизирует разницу в комфортности:

$$\min \sum_{j \in S \cup N'} (K_j^- - K_j^+)^2, \quad (4)$$

где K_j^- и K_j^+ рассчитываются на основании расстояний до ближайших соседей и границ строки:

$$\begin{aligned} K_j^- &= \frac{x_j - (x_{left} + w_{left} + D_{left}^+)}{D_j^-}; \\ K_j^+ &= \frac{(x_{right} - D_{right}^- - w_j - x_j)}{D_j^+}. \end{aligned} \quad (5)$$

Переменные x_{left} и x_{right} определяют границы соседей слева и справа соответственно. Для объектов на краях строки значения x_{left} или x_{right} принимаются равными границам плоскости 0 или W .

Таким образом, базовый подход направлен на последовательное упорядоченное размещение объектов с учетом их размеров и ограничений на буферные зоны. Этот процесс задает начальную структуру размещения, на основе которой в дальнейшем производятся уточнение и модификации.

Модифицированный алгоритм и динамическое программирование

Модифицированный метод решения основывается на базовом подходе оптимальной 2D-расстановки, но адаптируется для учета уже установленных объектов и их влияния на новые элементы. В отличие от исходного алгоритма, новая версия включает этапы перерасчета партий

и локальной корректировки для минимизации конфликта между новыми и ранее размещенными элементами.


В общем виде описываемый процесс представлен на рис. 1.

На первом этапе формируются партии объектов, которые подлежат размещению. Каждая партия $B \subseteq N$ строится таким образом, чтобы ее суммарная ширина, включая буферные зоны, удовлетворяла условию

$$\sum_{j \in B} (w_j + D_j^- + D_j^+) \leq W. \quad (6)$$

Этот процесс организуется на основе существующего алгоритма, но с учетом ограничений, задаваемых уже установленными объектами S . При этом структура партии оптимизируется для минимизации внутренних конфликтов между ее элементами.

После формирования партии проводится проверка на пересечения между объектами из B и S .



■ **Рис. 1.** Блок-схема модифицированной версии оригинального алгоритма

■ **Fig. 1.** Block diagram of the modified version of the original algorithm

Пересечение фиксируется, если выполнены условия

$$(x_j + w_j + D_j^+ > x_i - D_i^-) \wedge (x_j - D_j^- < x_i + w_i + D_i^+) \wedge (y_j + h_j + Z_j^+ > y_i - Z_i^-) \wedge (y_j - Z_j^- < y_i + h_i + Z_i^+), \quad \forall j \in B, i \in S. \quad (7)$$

Эти проверки позволяют выявить зоны конфликта и перейти к следующему этапу — локальной корректировке.

Для каждого пересекающегося j -го объекта из партии S определяется его положение относительно двух соседей — одного слева, другого справа. Эти соседи выбираются из текущей партии B , причем критерий выбора формулируется как

$$x_{left} + w_{left} + D_{left}^+ \leq x_j - D_j^-; \quad x_{right} - D_{right}^- \geq x_j + w_j + D_j^+. \quad (8)$$

На основе этой информации рассчитывается новая координата x_j , минимизирующая дисбаланс в комфортности:

$$\min |(x_j - x_{left} - w_{left} - D_{left}^+) - (x_{right} - x_j - w_j - D_j^+)|. \quad (9)$$

Здесь используется динамическое программирование (DP), чтобы найти подмножество объектов, которое максимально эффективно заполняет строку, не нарушая ее ограничений. Его использование играет важную роль в обеспечении вычислительной эффективности. Масштабирование и дискретизация входных параметров позволяют адаптировать задачу к ограниченным ресурсам, снижая общую сложность алгоритма. Это особенно важно при увеличении числа объектов или размера сцены, где точечный пересчет для каждой партии снижает избыточные вычисления. Подобные методы успешно применяются и в смежных задачах оптимального размещения с учетом внешних ограничений [18].

Алгоритм перераспределения начинается с объединения множества новых объектов N и уже установленных элементов S в единый массив. Каждый элемент помечается как «добавленный» или «существующий», что позволяет эффективно разделять операции на этапах проверки и перераспределения. Это объединение формализуется как расширенное множество

$$E = \{(s_i, false) | s_i \in S\} \cup \{(n_j, true) | n_j \in N\}. \quad (10)$$

Далее вычисляется максимальная допустимая длина строки, определяемая как

$$L_{\max} = W - \sum_{j \in B} (w_j + D_j^- + D_j^+), \quad (11)$$

где B — текущая партия новых объектов, уже добавленных в строку. Этот параметр служит ограничением для включения новых объектов и позволяет сохранить установленные элементы в их исходных позициях.

Для повышения точности и удобства применения алгоритма динамического программирования размеры объектов масштабируются. Пусть масштабный коэффициент равен α , тогда ширина каждого объекта w_j и допустимая длина строки $L_{\max}$ преобразуются в целые значения:

$$w_j^{scaled} = \lfloor \alpha w_j \rfloor; \quad L_{\max}^{scaled} = \lfloor \alpha L_{\max} \rfloor. \quad (12)$$

Это позволяет использовать дискретную модель для последующего анализа.

Инициализируем массив достижимых сумм $dp[t]$, где t — текущее значение длины строки. Этот массив позволяет определить, какие размеры могут быть достигнуты с текущим набором объектов:

$$dp[t] = \max(dp[t], dp[t - w_j^{scaled}] + w_j^{scaled}), \quad \forall j \in B. \quad (13)$$

Одновременно с этим отслеживаются индексы выбранных объектов, что необходимо для восстановления их позиций на следующем этапе. Пусть $I[t]$ хранит множество индексов объектов, составляющих сумму t . Тогда обновление происходит по правилу

$$I[t] = \begin{cases} I[t], & \text{если } dp[t] \geq dp[t - w_j^{scaled}] + w_j^{scaled}; \\ I[t - w_j^{scaled}] \cup \{j\} & \text{иначе.} \end{cases} \quad (14)$$

После завершения этапа DP те объекты, которые не удалось включить в текущую строку, возвращаются в общий пул. Это гарантирует, что они будут рассмотрены при формировании следующих партий. При этом оставшиеся элементы из текущей строки корректируются по координатам для минимизации конфликтов:

$$x_j = x_{prev} + w_{prev} + D_{prev}^+, \quad \forall j \in B, \quad (15)$$

где x_{prev} — координата предыдущего объекта.

Завершающий этап перераспределения включает корректировку позиций объектов с учетом соседей и границ строки. Этот шаг минимизирует влияние новых элементов на уже установленные, сохраняя их перцептивное состояние.

Таким образом, модификация позволяет эффективно интегрировать новые объекты без значительного нарушения структуры сцены.

Финальным шагом для партии является уточнение позиций объектов на основании их скорректированных координат. Это включает восстановление порядка внутри партии и минимизацию влияния новых элементов на перцептивное состояние уже установленных объектов. После завершения всех операций партия размещается, и алгоритм переходит к следующей партии. Процесс повторяется до тех пор, пока не будут размещены все объекты или не будет исчерпано доступное пространство.

Экспериментальная проверка

Для оценки производительности предложенного алгоритма размещения виртуальных объектов был проведен анализ временных характеристик на различных процессорных архитектурах. Основное внимание уделялось снижению вычислительных затрат при увеличении количества объектов и оценке устойчивости алгоритма к выбросам в данных.

Для анализа экспериментально собранных данных использовался метод винсоризации для обработки выбросов, что позволило минимизировать влияние экстремальных значений на результаты расчетов. Данный метод, активно применяемый в статистическом моделировании и машинном обучении, доказал свою эффективность в области обработки данных с высокой вариативностью [19]. Кроме того, в контексте выборки по важности адаптивная винсоризация может уменьшить дисперсию и улучшить среднеквадратичную ошибку оценок, что выгодно для мобильных приложений, где вычислительная эффективность и точность имеют первостепенное значение [20]. Было показано, что метод визоризованных моментов обеспечивает надежную оценку параметров в моделях, работающих с усеченными и подвергнутыми цензуре данными, что актуально для мобильных приложений, обрабатывающих большие наборы данных с потенциальными выбросами [21].

В ходе исследования была проведена экспериментальная проверка производительности алгоритма размещения виртуальных объектов в ограниченном пространстве. Для этого использовался автоматизированный сценарий тестирования, выполняющий серию измерений на различных конфигурациях сцены и устройств. Тестирование проводилось на трех категориях платформ: персональных компьютерах (PC), устройствах на базе iOS и устройствах на базе Android. В качестве тестовых процессоров ис-

пользовались Intel i7-12700, Intel i9-10900KF, Apple M1 Pro, A12 Bionic, A15 Bionic, A17 Pro, Snapdragon 845, Snapdragon 732G и Google Tensor GS101.


Тестирование включало измерение времени выполнения алгоритма при увеличении количества объектов в сцене от 0 до 50, с добавлением новых элементов от 1 до 50 в каждом запуске. Каждое испытание повторялось не менее 100 раз, что позволило сгладить возможные случайные флуктуации. Размер доступного пространства составлял 10×10 условных единиц, однако в процессе работы он динамически изменялся в зависимости от общего количества объектов, что позволяло учитывать влияние плотности размещения. Перед основными испытаниями выполнялся разогрев системы с фиксированными параметрами, чтобы исключить влияние предварительной компиляции кода и возможных особенностей кеширования.

Результаты тестирования показали, что при количестве объектов от 0 до 20 алгоритм демонстрирует линейный рост времени выполнения со средними значениями ниже 2 мс на всех платформах. Однако при превышении 30 объектов на сцене наклон кривой существенно возрастает, особенно на мобильных устройствах, что указывает на более высокие вычислительные затраты (рис. 2).

Для наглядного представления данных в диапазоне 0÷50 уже установленных объектов, к которым последовательно добавлялось от 0 до 50 новых объектов, было решено сгруппировать результаты по «корзинам» (bin), чтобы избежать избыточного загромождения графика. Каждая корзина (XS, S, M и т. д.) соответствует определенному диапазону количества объектов, отражая совокупность тестовых значений в этой группе. XS, S, M и другие аббревиатуры обозначают размер корзины: XS — очень маленькая, S — маленькая, M — средняя и т. д. Такой подход позволяет упростить визуализацию и указывает на тенденции изменения времени выполнения без потери ключевых особенностей распределения.


Персональные компьютеры продемонстрировали среднее время выполнения 1,30 мс, в то время как на iOS-устройствах (A12 Bionic, A15 Bionic, A17 Pro) этот показатель составил 0,57 мс, а на Android-устройствах (Snapdragon 732G, Snapdragon 845, Google Tensor GS101) — 1,72 мс. Таким образом, наиболее высокую производительность показала платформа iOS, а Android уступает ей почти в три раза.

Дополнительно был проведен анализ работы алгоритма в условиях небольших сцен (до 20 объектов), что более характерно для реальных прикладных задач (рис. 3). В этом диапазоне Android-



■ **Рис. 2.** Среднее время выполнения алгоритма в зависимости от количества объектов. Разница между 0–10 и 11–20 незначительна и может быть не видна из-за наложения линий

■ **Fig. 2.** Average execution time of the algorithm depending on the number of objects. The difference between 0–10 and 11–20 is insignificant and may not be visible due to overlapping lines




■ **Рис. 3.** Среднее время выполнения при малом числе объектов

■ **Fig. 3.** Average execution time with a small number of objects

устройства в среднем достигают 0,0745 мс, в то время как PC и iOS демонстрируют 0,0205 и 0,0170 мс соответственно. Несмотря на заметный разрыв между платформами, во всех случаях сохраняется линейная зависимость времени выполнения от числа объектов, что говорит о стабильной работе алгоритма при таком уровне нагрузки.

Для определения сложности алгоритма была построена модель кусочной линейной регрессии зависимости времени выполнения от общего числа объектов на сцене (рис. 4). Модель разбита на три диапазона: от 0 до 35 объектов, от 35 до 70 объектов и свыше 70 объектов. Анализ результатов показывает, что в первом диапазоне наблюдается относительно слабая линейная связь (коэффициенты корреляции r составляют 0,33 для iOS, 0,57 для PC и 0,37 для Android). Во втором диапазоне зависимость становится умеренной ($r \approx 0,41 \div 0,44$). Наиболее выраженная линейная зависимость фиксируется в третьем диапазоне: для PC и Android наблюдаются зна-



■ **Рис. 4.** Линейная зависимость времени выполнения от общего количества объектов

■ **Fig. 4.** Linear dependence of execution time on the total number of objects

чения r около 0,70–0,71, при этом наклон линии для Android (0,4223) значительно превышает соответствующий показатель для iOS (0,1581). Эти данные свидетельствуют о том, что при значительном увеличении числа объектов (свыше 70) время выполнения алгоритма растет быстрее, что особенно заметно для мобильных устройств, в первую очередь для платформы Android.

На основании полученных результатов можно заключить, что алгоритм эффективно работает для небольших сцен, где общее число объектов не превышает 35. В этом диапазоне время выполнения увеличивается очень слабо (коэффициенты наклона порядка 0,0006–0,0018 мс на объект для различных платформ), что свидетельствует о линейном характере зависимости и высокой производительности, особенно на персональных компьютерах и iOS-устройствах.

При переходе ко второму диапазону (от 35 до 70 объектов) наблюдается умеренное увеличение наклона регрессионной линии, а в третьем диапазоне (свыше 70 объектов) — значительно более выраженное. Так, для PC и Android коэффициенты наклона составляют 0,3514 и 0,4223 мс на объект соответственно, в то время как для iOS — 0,1581 мс на объект. Это указывает на снижение масштабируемости алгоритма на мобильных устройствах, особенно на Android-платформах с процессорами Snapdragon 732G и Google Tensor GS101.

Заключение

В данной работе представлен алгоритм идеального размещения объектов в XR-пространстве, позволяющий интегрировать новые элементы в уже оптимизированные композиции с учетом их физических размеров и зон комфорта. Разработанный подход объединяет классические методы статической оптимизации с динамическими механизмами локальной настройки, что позволяет минимизировать перерасчет позиций и сохранять исходную структуру сцены.

Экспериментальная проверка демонстрирует, что при размещении небольшого числа объектов (до 35) время выполнения алгоритма растет линейно, что делает его эффективным для большинства практических приложений. Однако при увеличении плотности объектов (свыше 70) наблюдается существенное ускорение роста вычислительных затрат. Результаты кусочного регрессионного анализа подтверждают, что, хотя общая зависимость остается линейной, увеличение наклона регрессионных линий в высоконагруженных диапазонах свидетельствует о необходимости дополнительной оптимизации для масштабных сцен.

Ключевым преимуществом предложенного алгоритма является возможность локального пересчета позиций объектов, что минимизирует влияние добавляемых элементов на уже существующую композицию и обеспечивает комфортное восприятие пользователем. Тем не менее в условиях высокой плотности объектов могут потребоваться дополнительные оптимизации, например реализация параллельных вычислений, использование аппаратного ускорения или разработка адаптивных стратегий распределения ресурсов для устройств с ограниченными вычислительными возможностями.

В целом результаты исследования подтверждают гипотезу о том, что стратегическая интеграция новых виртуальных объектов в предварительно оптимизированную композицию позволяет повысить вычислительную эффективность без ущерба для качества размещения и пользовательского опыта. Будущие исследования могут быть направлены на адаптацию алгоритма к трехмерным и динамическим условиям, что позволит еще больше раскрыть потенциал расширенной реальности в реальных приложениях.

Литература

1. El Barhoumi N., Hajji R., Bouali Z., Ben Brahim Y., Kharroubi A. Assessment of 3D models placement methods in augmented reality. *Applied Sciences*, 2022, vol. 12, no. 20, Article 10620. doi:10.3390/app122010620
2. He X., Zhou K. Display in the air: Balancing distraction and workload in AR glasses interfaces for driving navigation. *arXiv*, 2024. doi:10.48550/arxiv.2404.18357
3. Ye K., Wu H., Tong X., Zhou K. A real-time method for inserting virtual objects into neural radiance fields. *arXiv*, 2023. doi:10.48550/arxiv.2310.05837

4. Nurhadi N., Stiawan D., Idris M. Y., Saparudin S. Object tracking in augmented reality: Enhancement using convolutional neural networks. *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, 2022, vol. 10, iss. 4. doi:10.52549/ije. v10i4.4104
5. Алпатова М. В., Рудяк Ю. В. Размещение нескольких виртуальных объектов в физическом пространстве в приложениях дополненной реальности. *Advanced Engineering Research (Rostov-on-Don)*, 2023, т. 23, № 2, с. 203–211. doi:10.23947/2687-1653-2023-23-2-203-211
6. Zhu-Tian C., Chiappalupi D., Lin T., Yang Y., Beyer J., Pfister H. RL-LABEL: A deep reinforcement learning approach intended for AR label placement in dynamic scenarios. *arXiv*, 2023. doi:10.48550/arxiv.2308.13540
7. Xing Y., Liu Q., Wang J., Gomez-Zara D. sMoRe: Enhancing object manipulation and organization in mixed reality spaces with LLMs and Generative AI. *arXiv*, 2024. doi:10.48550/arxiv.2411.11752
8. Алпатова М. В., Рудяк Ю. В. Оптимальная 2D-расстановка виртуальных объектов в физическом пространстве для приложений дополненной реальности. *Advanced Engineering Research (Rostov-on-Don)*, 2023, т. 23, № 4, с. 410–421. doi:10.23947/2687-1653-2023-23-4-410-421
9. Xu Y., Wu Y., Zhou H. Multi-scale voxel hashing and efficient 3d representation for mobile augmented reality. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, US, June 18–22, 2018, pp. 1586–15867. doi:10.1109/CVPRW.2018.00200
10. Magassouba A., Sugiura K., Nakayama A., Hirakawa T., Yamashita T., Fujiyoshi H., Kawai H. Predicting and attending to damaging collisions for placing everyday objects in photo-realistic simulations. *Advanced Robotics*, 2021, vol. 35, no. 12, pp. 787–799. doi:10.1080/01691864.2021.1913446
11. Zanyk-McLean S., Kumar K., Navratil P. 3D object positioning using differentiable multimodal learning. *arXiv*, 2023. doi:10.48550/arxiv.2309.03177
12. Weiß M. Optimal object placement using a virtual axis. *arXiv*, 2019. https://doi.org/10.48550/arXiv.1901.00168
13. Wiethüchter R., Kalloori S., Chalumattu R. Fast content placement and alignment in 3D scenes. *The International FLAIRS Conference Proceedings*, 2022, vol. 35. doi:10.32473/flairs.v35i.130686
14. Wang H. Haptic repurposing with GenAI: Transforming the tangible world into adaptive haptic interfaces in mixed reality. *arXiv*, 2024. doi:10.48550/arXiv.2406.07228
15. Jia J., Elezovikj S., Fan H., Yang S., Liu J., Guo W., Tan C. C., Ling H. Semantic-aware label placement for augmented reality in street view. *The Visual Computer*, 2021, vol. 37, no. 7, pp. 1805–1819. doi:10.1007/S00371-020-01939-W
16. Zhao X., Rao Y., Qi P., Lyu Q., Yang P., Yu S. An efficient constructive heuristic for the rectangular packing problem with rotations. *PloS One*, 2023, vol. 18, no. 12. doi:10.1371/journal.pone.0295206
17. Douglas C., Huh J. S., Jun S. O., Kim I. Y. Packing optimization of practical systems using a dynamic acceleration methodology. *Journal of Engineering and Applied Science*, 2024, vol. 71, no. 1. doi:10.1186/s44147-024-00426-6
18. Chen D., Mo F., Chen Y., Zhang J., You X. Optimization of ramp locations along freeways: A dynamic programming approach. *Sustainability*, 2022, vol. 14, no. 15, Article 9718. doi:10.3390/su14159718
19. Boudt K., Todorov V., Wang W. Robust distribution-based winsorization in composite indicators construction. *Social Indicators Research*, 2020, vol. 149, no. 2, pp. 375–397. doi:10.1007/s11205-019-02259-w
20. Orenstein P. Robust importance sampling with adaptive winsorization. *Bernoulli*, 2022, vol. 28, no. 4. doi:10.3150/21-bej1440
21. Poudyal C., Zhao Q., Brazauskas V. Method of winsorized moments for robust fitting of truncated and censored lognormal distributions. *North American Actuarial Journal*, 2024, vol. 28, no. 1, pp. 236–260. doi:10.1080/10920277.2023.2183869

UDC 004.946

doi:10.31799/1684-8853-2025-3-49-58

EDN: SKBXGY

Optimization of virtual object placement in extended reality using dynamic programmingM. V. Alpatova^a, PhD, Tech., Associate Professor, orcid.org/0000-0003-3018-9601, m.v.alpatova@yandex.ruY. V. Rudyak^b, Dr. Sc., Phys.-Math., Professor, orcid.org/0000-0001-7886-0455^aMIREA – Russian Technological University, 78, Vernadsky Ave., 119454, Moscow, Russian Federation^bMoscow Polytechnic University, 38, Bolshaya Semyonovskaya St., 107023, Moscow, Russian Federation

Introduction: The rapid advancement of extended reality (XR) technologies imposes stringent requirements on the precise placement of virtual objects to ensure an optimal user experience. In dynamic scenes with limited computational resources, integrating new objects into an already optimized composition remains a significant challenge. **Purpose:** To develop and experimentally evaluate an algorithm for placing virtual objects in XR space with a focus on computational efficiency. **Results:** We propose a modified algorithm for optimal two-dimensional arrangement based on dynamic programming principles and local adjustments. The algorithm first sorts objects by size, then sequentially places them while minimizing imbalances in zones of perceptual comfort, and finally recalculates positions locally to integrate

new elements without disrupting the scene's initial structure. Our experimental evaluation demonstrates that the algorithm effectively places objects according to their physical dimensions and comfort zones. The timing characteristics show a linear increase in execution time for a small number of objects (up to 35). However, as the number of objects increases (within the range of 35–70 and beyond), the execution time grows at an accelerated rate, particularly on mobile devices. Regression analysis reveals a strong correlation between the number of objects and execution time for personal computers and iOS devices, while Android platforms exhibit lower scalability. **Practical relevance:** We validate that the proposed method applies effectively in real XR scenarios, reducing computational load and enhancing the adaptability of XR systems. **Discussion:** Our findings open prospects for further optimizing the algorithm through parallel computing and hardware acceleration, as well as extending its functionality to three-dimensional environments.

Keywords — extended reality, virtual objects, optimal placement, dynamic programming, computational efficiency, buffer zones, perceptual state, placement algorithms, mobile devices, regression analysis.

For citation: Alpatova M. V., Rudyak Y. V. Optimization of virtual object placement in extended reality using dynamic programming. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 49–58 (In Russian). doi:10.31799/1684-8853-2025-3-49-58, EDN: SKBXGY

References

1. El Barhoumi N., Hajji R., Bouali Z., Ben Brahim Y., Kharroubi A. Assessment of 3D models placement methods in augmented reality. *Applied Sciences*, 2022, vol. 12, no. 20, Article 10620. doi:10.3390/app122010620
2. He X., Zhou K. Display in the air: Balancing distraction and workload in AR glasses interfaces for driving navigation. *arXiv*, 2024. doi:10.48550/arxiv.2404.18357
3. Ye K., Wu H., Tong X., Zhou K. A real-time method for inserting virtual objects into neural radiance fields. *arXiv*, 2023. doi:10.48550/arxiv.2310.05837
4. Nurhadi N., Stiawan D., Idris M. Y., Saparudin S. Object tracking in augmented reality: Enhancement using convolutional neural networks. *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, 2022, vol. 10, iss. 4. doi:10.52549/ijeiv10i4.4104
5. Alpatova M. V., Rudyak Y. V. Placement of multiple virtual objects in physical space in augmented reality applications. *Advanced Engineering Research*, 2023, vol. 23, no. 2, pp. 203–211 (In Russian). doi:10.23947/2687-1653-2023-23-2-203-211
6. Zhu-Tian C., Chiappalupi D., Lin T., Yang Y., Beyer J., Pfister H. RL-LABEL: A deep reinforcement learning approach intended for AR label placement in dynamic scenarios. *arXiv*, 2023. doi:10.48550/arxiv.2308.13540
7. Xing Y., Liu Q., Wang J., Gomez-Zara D. sMoRe: Enhancing object manipulation and organization in mixed reality spaces with LLMs and Generative AI. *arXiv*, 2024. doi:10.48550/arxiv.2411.11752
8. Alpatova M. V., Rudyak Y. V. Optimal 2D placement of virtual objects in physical space for augmented reality applications. *Advanced Engineering Research*, 2023, vol. 23, no. 4, pp. 410–421 (In Russian). doi:10.23947/2687-1653-2023-23-4-410-421
9. Xu Y., Wu Y., Zhou H. Multi-scale voxel hashing and efficient 3d representation for mobile augmented reality. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, US, June 18–22, 2018, pp. 1586–15867. doi:10.1109/CVPRW.2018.00200
10. Magassouba A., Sugiura K., Nakayama A., Hirakawa T., Yamashita T., Fujiyoshi H., Kawai H. Predicting and attending to damaging collisions for placing everyday objects in photo-realistic simulations. *Advanced Robotics*, 2021, vol. 35, no. 12, pp. 787–799. doi:10.1080/01691864.2021.1913446
11. Zanyk-McLean S., Kumar K., Navratil P. 3D object positioning using differentiable multimodal learning. *arXiv*, 2023. doi:10.48550/arxiv.2309.03177
12. Weiß M. Optimal object placement using a virtual axis. *arXiv*, 2019. https://doi.org/10.48550/arXiv.1901.00168
13. Wiethüchter R., Kalloori S., Chalumattu R. Fast content placement and alignment in 3D scenes. *The International FLAIRS Conference Proceedings*, 2022, vol. 35. doi:10.32473/flairs.v35i.130686
14. Wang H. Haptic repurposing with GenAI: Transforming the tangible world into adaptive haptic interfaces in mixed reality. *arXiv*, 2024. doi:10.48550/arXiv.2406.07228
15. Jia J., Elezovikj S., Fan H., Yang S., Liu J., Guo W., Tan C. C., Ling H. Semantic-aware label placement for augmented reality in street view. *The Visual Computer*, 2021, vol. 37, no. 7, pp. 1805–1819. doi:10.1007/S00371-020-01939-W
16. Zhao X., Rao Y., Qi P., Lyu Q., Yang P., Yu S. An efficient constructive heuristic for the rectangular packing problem with rotations. *PloS One*, 2023, vol. 18, no. 12. doi:10.1371/journal.pone.0295206
17. Douglas C., Huh J. S., Jun S. O., Kim I. Y. Packing optimization of practical systems using a dynamic acceleration methodology. *Journal of Engineering and Applied Science*, 2024, vol. 71, no. 1. doi:10.1186/s44147-024-00426-6
18. Chen D., Mo F., Chen Y., Zhang J., You X. Optimization of ramp locations along freeways: A dynamic programming approach. *Sustainability*, 2022, vol. 14, no. 15, Article 9718. doi:10.3390/su14159718
19. Boudt K., Todorov V., Wang W. Robust distribution-based winsorization in composite indicators construction. *Social Indicators Research*, 2020, vol. 149, no. 2, pp. 375–397. doi:10.1007/s11205-019-02259-w
20. Orenstein P. Robust importance sampling with adaptive winsorization. *Bernoulli*, 2022, vol. 28, no. 4. doi:10.3150/21-bej1440
21. Poudyal C., Zhao Q., Brazauskas V. Method of winsorized moments for robust fitting of truncated and censored lognormal distributions. *North American Actuarial Journal*, 2024, vol. 28, no. 1, pp. 236–260. doi:10.1080/10920277.2023.2183869



Кластеризация абонентов в когнитивной системе управления реконфигурируемой интеллектуальной поверхностью для систем связи 5G/6G

В. А. Павлов^а, канд. техн. наук, доцент, orcid.org/0000-0003-0726-6613, pavlov_va@spbstu.ru

А. А. Белов^а, ведущий инженер, orcid.org/0000-0003-0617-4514

Ф. Шариати^а, аспирант, ассистент, orcid.org/0000-0002-7060-8826

^аСанкт-Петербургский политехнический университет Петра Великого, Политехническая ул., 29, Санкт-Петербург, 195251, РФ

Введение: повышение эффективности работы систем связи миллиметрового диапазона является актуальной задачей в области телекоммуникаций. Использование вспомогательных систем компьютерного зрения для улучшения управления лучом реконфигурируемых интеллектуальных поверхностей представляет значительный интерес при разработке систем 5G/6G миллиметрового диапазона. **Цель:** разработать и протестировать методы, использующие компьютерное зрение для точного определения положения абонентов и на основании этой информации оптимизирующие формирование диаграммы направленности антенн в системах связи миллиметрового диапазона. **Методы:** исследование включало моделирование зон покрытия лучом реконфигурируемой интеллектуальной поверхности для оценки размеров, формы и ориентации этих зон. Получены и использованы приближенные формулы для формы и размеров зон покрытия одним лучом. Для обнаружения пешеходов применялась сверточная нейронная сеть YOLOv11, а для группировки близко расположенных пользователей — метод кластеризации DBSCAN. Оценка качества связи проводилась с использованием коэффициента покрытия (отношения общего количества пользователей к количеству обеспеченных связью). **Результаты:** проведено моделирование работы системы связи миллиметрового диапазона 5G. В итоге установлено, что зона покрытия одного луча имеет форму вытянутого эллипса, размеры и ориентация которого зависят от положения точки пересечения максимума излучения антенны с земной поверхностью. Тестирование с использованием реальных видеозаписей подтвердило эффективность предложенных методов управления лучом антенны. В частности, выявлено, что использование многолучевого режима работы реконфигурируемой интеллектуальной поверхности обеспечивает заметное улучшение качества связи в случае большого количества абонентов. Количественные оценки показали, что оптимальное количество лучей обычно не превышало четырех. **Практическая значимость:** результаты исследования имеют важное практическое значение для разработки и оптимизации работы систем связи миллиметрового диапазона. Использование предложенных методов позволяет повысить эффективность управления лучом и улучшить качество связи в условиях большого количества абонентов.

Ключевые слова — компьютерное зрение, реконфигурируемая интеллектуальная поверхность, кластеризация, обнаружение объектов, системы связи 5G/6G, мобильная связь.

Для цитирования: Павлов В. А., Белов А. А., Шариати Ф. Кластеризация абонентов в когнитивной системе управления реконфигурируемой интеллектуальной поверхностью для систем связи 5G/6G. *Информационно-управляющие системы*, 2025, № 3, с. 59–68. doi:10.31799/1684-8853-2025-3-59-68, EDN: UTJUNH

For citation: Pavlov V. A., Belov A. A., Shariaty F. Clustering of users in cognitive control system of reflective intelligent surface for 5G/6G communication systems. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 59–68 (In Russian). doi:10.31799/1684-8853-2025-3-59-68, EDN: UTJUNH

Введение

В современном мире беспроводные коммуникации играют ключевую роль в обеспечении связи. С переходом на системы 5G/6G требования к качеству обслуживания, скорости передачи данных и эффективности использования излучаемой мощности становятся все более высокими. С целью расширить полосы пропускания и повысить скорость передачи информации производится переход на более высокие частоты, вплоть до миллиметровых волн (ММВ). Системы 5G уже используют ММВ при работе в диапазоне FR2 (24–52 ГГц). Однако по сравнению с более низкочастотными диапазонами FR1 (частоты

ниже 6 ГГц) применение ММВ имеет существенные особенности, связанные как с характером распространения ММВ, так и с новыми принципами построения и работы базовых станций (БС). Во-первых, любые затеняющие абонентов препятствия на пути распространения ММВ (дома, деревья и т. п.) снижают уровень принятого абонентским терминалом сигнала и практически всегда приводят к полному нарушению связи. Во-вторых, антенны ММВ (обычно это фазированные антенные решетки) часто имеют узкие диаграммы направленности (ДН). Одним из перспективных направлений развития в области совершенствования связи на ММВ является использование реконфигурируемых интеллекту-

альных поверхностей (РИП), которые позволяют динамически управлять электромагнитными волнами. Специально размещенные РИП способны переотражать сигналы БС ММ-диапазона в теневые зоны и могут значительно повысить эффективность как существующих, так и перспективных систем связи за счет расширения зоны покрытия БС. Но узкие ДН антенн ММВ не способны обеспечить одномоментное покрытие большой площади и требуют точного наведения на абонента. Связанные с этим задачи пока находятся в стадии решения. Одним из подходов является использование вспомогательных систем компьютерного зрения, определяющих наличие и положение абонентов и передающих информацию БС и РИП для использования в алгоритмах управления лучом.

В работе [1] для управления системы 6G, работающей в диапазоне терагерцовых частот, используется система компьютерного зрения. Основная идея заключается в применении визуальной информации для упреждающего переключения соединения, что позволяет максимизировать пропускную способность системы. Предложенная авторами система использует глубокое обучение для обнаружения пользователей, предсказания их траекторий и прогнозирования качества связи, что позволяет минимизировать потери из-за блокировок сигнала. Результаты экспериментов показывают, что предложенная система обеспечивает увеличение пропускной способности на 30 % по сравнению с традиционными методами управления мобильностью. Особенностью работы является проведение экспериментальных исследований исключительно внутри помещений ограниченного размера.

В работах [2, 3] описан пример интеграции РИП, функционирующей в диапазоне ММВ, и системы компьютерного зрения, расположенных вне помещения. Для выбора оптимальной ДН в работе [2] используется генетический алгоритм. В [3] показано, что при высокой загруженности сети совместное использование РИП и системы компьютерного зрения позволяет снизить средний уровень взаимных помех на 40 %.

В работе [4] описан пример моделирования использования компьютерного зрения для формирования ДН в системе ММО ММ-диапазона на основе синтетического набора данных [5]. Результаты моделирования свидетельствуют о том, что использование визуальных данных может значительно улучшить точность прогнозирования ДН.

В работе [6] также проводилось моделирование на синтетическом наборе данных [5]. Для управления РИП в [6] использовали YOLOv3. Авторы продемонстрировали, что предложенный метод визуального контроля способен обес-

печить почти оптимальную достижимую скорость при значительно меньших затратах на обучение синтезу ДН, что свидетельствует о потенциале применения визуальной информации для повышения эффективности систем связи с РИП.

В [7] в качестве системы компьютерного зрения авторы использовали сочетание стереокамеры и алгоритма YOLOX. Эксперименты проводились с РИП размером 20×20 элементов на частоте 5,4 ГГц. В работе показано, что РИП под управлением системы компьютерного зрения способен быстро корректировать коэффициенты отражения при динамическом сопровождении пользователя. Однако с увеличением расстояния до пользователей возрастает сложность и снижается точность работы системы компьютерного зрения.

В работах [8–10] представлено решение проблемы увеличения зоны покрытия в современных высокочастотных системах мобильной связи. Решение заключается в использовании компьютерного зрения для управления ДН РИП. Показано, что при использовании РИП, работающего под управлением системы компьютерного зрения, канал связи может быть создан в теневых зонах передатчика при работе в помещении сложной формы, таком как L-образный коридор. Это значительно увеличивает мощность принимаемого сигнала на 15–20 дБ, что делает ее достаточной для надежной работы абонентского оборудования.

В [11] был разработан нейросетевой детектор объектов, обученный и протестированный на разработанном авторами работы наборе данных, состоящем из 20232 пар изображений (цветного изображения и карты глубины), полученных с камеры, прикрепленной к БС, расположенной внутри помещения. Каждая пара изображений содержит информацию о категории объекта (человек, мобильный телефон и ноутбук) и его положения в кадре (ограничительные прямоугольники). Результаты, полученные авторами (Precision 94,46 %, Recall 81,04, F1-score 87,24 %), показали перспективность применения технологии формирования ДН с помощью нейросетевого детектора, обученного на специализированном наборе данных.

В работе [12] разработали систему прогнозирования блокировок и упреждающего переключения (handover) для систем связи внутри помещения в диапазонах крайне высоких и терагерцовых частот, которые критичны для систем 6G. Авторы предлагают метод, основанный на анализе последовательностей RGB-D-изображений и индексов лучей, для обнаружения пользователей и препятствий, предсказания их траекторий и прогнозирования блокировок. Основная идея заключается в разделении стационарного фона

и движущихся объектов, что позволяет снизить задержки и энергопотребление по сравнению с традиционными методами. Результаты экспериментов показывают, что предложенная система достигает точности прогнозирования блокировок до 97 % и позволяет минимизировать потери в пропускной способности из-за блокировок.

В работе [13] для управления РИП используется система компьютерного зрения на базе RGB-D-камеры, нейросетевого детектора YOLOv4-tiny [14] для обнаружения и SORT [15] для сопровождения пользователей. Для формирования ДН используется предобученная нейронная сеть ResNet34 [16], информация с выхода которой передается на ПЛИС для управления РИП. Эксперименты в безэховой камере продемонстрировали способность системы отслеживать цели и передавать данные с высокой точностью.

В [17] представлена система на базе компьютерного зрения для управления ДН базовой станции. Система захватывает изображение, а детектор объектов на основе глубокого обучения определяет 3D-местоположение абонента. Поскольку в этом случае БС может напрямую определять направление ДН, то данная система позволяет добиться значительного выигрыша в скорости формирования ДН. Авторы показали, что благодаря системе компьютерного зрения достигается более чем 40-процентное улучшение среднего коэффициента усиления антенны.

Из обзора и анализа источников [1–17] можно сделать вывод, что задача сопряжения алгоритмов компьютерного зрения и РИП является перспективной и относительно мало проработанной для случая связи вне помещений. В то же время в работах отсутствует исследование влияния кластеризации на эффективность обслуживания абонентов. Отдельно стоит отметить актуальность исследования сопряжения алгоритмов компьютерного зрения, РИП и кластеризации применительно к работе вне помещения. Данная проблема не исследована в должной мере и представляет как научный, так и практический интерес.

Цель настоящей работы заключается в разработке и тестировании методов, которые позволят точно определять положение абонентов и оптимизировать зоны покрытия в системах связи миллиметрового диапазона.

Моделирование зоны покрытия

Для определения параметров зоны покрытия было проведено моделирование плоской прямоугольной РИП, переотражающей сигнал от БС ММ-диапазона (5G FR2) в теньевую зону [18]. При

моделировании распространения ММВ использовалось уравнение Фрииса [18] и известные параметры антенн. Определялась мощность на входе приемника абонентского терминала в зависимости от его положения в зоне работы РИП.

При моделировании использовались следующие параметры:

- рабочая частота: 28 ГГц;
- мощность БС: 40 дБм;
- коэффициент усиления антенны БС: 30 дБ;
- координаты БС: $X = -125$ м, $Y = 10$ м, $Z = 75$ м;
- размеры РИП: 240×240 мм;
- количество элементов РИП: 48×48 ;
- координаты РИП: $X = 0$ м, $Y = 10$ м, $Z = 0$ м;
- пороговая чувствительность приемника: -90 дБм;
- коэффициент усиления антенны приемника: 6 дБ;
- дополнительные потери мощности по разным причинам: 10 дБ.


На рис. 1 показан сектор работы РИП $\pm 60^\circ$ по углу и 150 м по дальности и распределение мощности сигнала на входе приемника абонентского терминала в пределах этого сектора.

Моделирование показало, что зона покрытия одного луча имеет форму, близкую к вытянутому эллипсу. Большая полуось эллипса направлена вдоль проекции направления максимума излучения антенны на земную поверхность, ее длина зависит от положения точки пересечения максимума излучения антенны с земной поверхностью. Малая полуось эллипса направлена поперек направления проекции максимума излучения антенны, а ее длина определяется шириной ДН.

Для рассматриваемого случая были получены следующие приближенные выражения для параметров этого эллипса (в метрах):

- большая полуось: $L_1 = 0,5 \times R + 5$;
- малая полуось: $L_2 = R \times \sin(2 \times A)$,

где R – точка пересечения максимума ДН с земной поверхностью; A – ширина ДН антенны по уровню половинной мощности.



■ Рис. 1. Пример зоны покрытия

■ Fig. 1. Example of the coverage area

Для согласования зоны покрытия с положением абонентов форма кластера также должна выбираться в форме эллипса, соответствующего эллипсу покрытия РИП и скорректированного с учетом положения и ориентации видеокамеры.

Описание метода кластеризации

В данной работе предлагается комплексный подход к использованию компьютерного зрения и методов кластеризации для оптимизации процесса формирования ДН в системах с РИП. Описание метода представлено на рис. 2.

Анализ литературы [19, 20] показал, что архитектура нейронной сети YOLOv11 [20] потенциально может быть эффективной при обнаружении небольших объектов (таких как пешеходы) с большого расстояния в различных ситуациях (таких как условия плотной городской застройки, в условиях низкой видимости), а также для интеграции с системами РИП для улучшения качества связи.

YOLOv11 содержит несколько ключевых архитектурных компонентов, значительно улучшающих извлечение признаков и производительность модели. В частности, внедрение блоков C3k2, SPPF и C2PSA позволяет модели более эффективно обрабатывать сложные сцены и объекты. Блок C3k2 (Cross Stage Partial с размером ядра 2) улучшает извлечение признаков, обеспечивая более точное и эффективное обнаружение объектов. Этот компонент позволяет модели лучше обрабатывать сложные сцены и объекты, повышая общую производительность. Блок SPPF (Spatial Pyramid Pooling – Fast) обеспечивает более эффективное использование вычислительных ресурсов, что особенно важно для приложений реального времени. Модуль C2PSA (сверточный блок с параллельным пространственным «вниманием») позволяет модели фокусироваться на наиболее важных частях изображения. C2PSA улучшает способность модели распознавать объекты в сложных и загроможденных сценах, повышая точность обнаружения.

YOLOv11 демонстрирует высокую среднюю точность (mAP) и вычислительную эффектив-

ность по сравнению с предыдущими версиями, сохраняя баланс между размером модели и точностью. Например, для версии YOLOv11x mAP составляет 54,7 % при размере входного изображения 640×640 пикселей на стандартном наборе данных COCO.

После обнаружения объектов применяется метод кластеризации DBSCAN для группировки пользователей. Этот метод позволяет эффективно группировать пользователей на основе их пространственного расположения, что упрощает процесс формирования ДН и повышает эффективность передачи данных.

Алгоритм DBSCAN (Density-Based Spatial Clustering of Applications with Noise) работает по принципу кластеризации на основе плотности. Он группирует точки данных (абонентов), которые находятся близко друг к другу, и отделяет точки, которые находятся в областях с низкой плотностью.

Рассмотрим основные шаги алгоритма.

1. Выбор параметров: задаются два параметра — радиус соседства (ϵ) и минимальное количество точек (MinPts), необходимых для формирования кластера.

2. Определение ядра: для каждой точки в наборе данных алгоритм проверяет, есть ли в ее ϵ -окрестности не менее MinPts точек. Если это условие выполняется, точка считается ядром кластера.


3. Расширение кластера: если точка является ядром, все точки в ее ϵ -окрестности, включая другие ядра, добавляются в тот же кластер. Этот процесс повторяется рекурсивно для всех соседних точек.

4. Обнаружение шума: точки, которые не принадлежат ни одному кластеру и не являются ядрами, считаются шумом.

Таким образом, DBSCAN эффективно выделяет кластеры произвольной формы и устойчив к выбросам.

Алгоритм DBSCAN позволяет гибко управлять структурой кластеров. Он строит упорядоченное представление данных и создает кластеры с учетом их плотности. Основные шаги алгоритма кластеризации абонентов включают:

1. Вычисление расстояний и углов: для каждой точки вычисляются расстояние и угол до



■ **Рис. 2.** Описание метода

■ **Fig. 2.** Description of the method

антенны. Расстояние d между точкой (x_i, y_i) и антенной (x_a, y_a) определяется как

$$d = \sqrt{(x_i - x_a)^2 + (y_i - y_a)^2}.$$

Угол θ между точкой и антенной вычисляется как

$$\theta = \arctg\left(\frac{y_i - y_a}{x_i - x_a}\right).$$

2. Нормализация признаков: углы нормализуются линейно в диапазоне от 0 до 1, а расстояния нормализуются нелинейно. Нормализация углов необходима, так как поле зрения камеры составляет 120° . Это позволяет упростить дальнейшую обработку данных. Нормализованные углы θ' вычисляются как

$$\theta' = \frac{2 \times \theta}{\pi/3}.$$

Нормализация расстояний необходима для того, чтобы на дальних расстояниях вес расстояния был меньше, так как эллипсы будут длиннее по вектору антенна-кластер. Нормализованные расстояния d' вычисляются как

$$d' = \left(1 - \exp\left(-\frac{d}{d_{\max}}\right)\right),$$

где $d_{\max}$ — максимальное расстояние среди всех точек. Это позволяет уменьшить влияние дальних точек на формирование эллипсов, что особенно важно для точного моделирования зон покрытия.

3. Кластеризация: для кластеризации нормализованных признаков используется алгоритм DBSCAN.


4. Разделение кластеров по углу: кластеры разделяются на подкластеры на основе углового расстояния. Если угловое расстояние между соседними точками превышает заданный порог, точками начинается новый подкластер.

5. Формирование эллипсов: для каждого подкластера вычисляется центр масс и ориентация. Эллипсы формируются на основе максимального углового расстояния и расстояния до антенны. Основная ось эллипса a и поперечная ось b вычисляются как

$$a = d_{\max} \sin(\theta_{\max}) \times 2,$$

$$b = a \times 0,6,$$

где $\theta_{\max}$ — максимальный угол, который равен 10° (определяется шириной ДН РИП).



■ **Рис. 3.** Процесс формирования кластеров

■ **Fig. 3.** The process of cluster formation

На основе результатов кластеризации формируются эллипсы (рис. 3), которые охватывают группы пользователей и используются для моделирования зон покрытия и оптимизации формирования ДН.

Для оценки эффективности предложенного подхода было проведено моделирование различных сценариев использования РИП в беспроводных сетях, которое позволяет оценить влияние метода кластеризации DBSCAN на эффективность системы и качество связи. Результаты моделирования демонстрируют, что предложенный подход значительно повышает эффективность обслуживания абонентов.

Для количественной оценки эффективности кластеризации используется метрика, определяемая как отношение числа абонентов, находящихся внутри сформированных эллиптических зон покрытия (n), к общему числу абонентов (N) в кадре:

$$\text{Coverage ratio} = \frac{n}{N}.$$

Эта метрика позволяет оценить, насколько точно метод кластеризации DBSCAN группирует абонентов и формирует эллипсы, охватывающие группы пользователей.

Управление РИП

Для определения требуемого угла отклонения РИП необходимо преобразовать координаты центра кластера (x, y) из декартовой системы координат в сферическую, чтобы найти углы θ и φ :

$$\theta = \left(\sqrt{x^2 + y^2} \right) \times \alpha,$$

где α — угол обзора камеры, равен 60° (определяется по результатам тестирования камеры);

$$\varphi = \arctg\left(\frac{y}{x}\right) + \frac{180^\circ}{\pi}.$$

Фазы элементов РИП, необходимые для отклонения луча на требуемые углы, могут быть рассчитаны по формуле [21]

$$w = \frac{2\pi}{\lambda} \sin \theta (\cos \varphi x_n + \sin \varphi y_n),$$

где λ — длина волны; x_n и y_n — координаты элемента РИП с номером n . В случае формирования многолучевой ДН распределения отдельных диаграмм комбинируются.

Результаты моделирования

Для оценки эффективности предлагаемого метода формирования ДН, основанного на интеграции алгоритма кластеризации DBSCAN и модели обнаружения объектов YOLOv11, были проведены эксперименты на видеопоследовательности из набора данных библиотеки OpenCV (<https://opencv.org/>). На данном видео абоненты перемещаются в различных направлениях и с разной скоростью, система должна в реальном времени корректировать зоны покрытия для обеспечения стабильного качества связи. В данной работе основным показателем эффективности выступает коэффициент покрытия (coverage ratio).

Формирование лучей в режиме реального времени иллюстрирует рис. 4. Зеленые эллипсы обозначают зоны покрытия, динамически сформированные на основе результатов кластеризации с использованием алгоритма DBSCAN. При этом обнаружение объектов, реализуемое посредством модели YOLOv11, обеспечивает высокую точность и оперативность в идентификации перемещающихся абонентов, что критически важно для адаптивного формирования зон покрытия.



Среднее значение метрики coverage ratio для предлагаемого метода составило 0,77, что свидетельствует о высокой точности кластеризации и эффективном моделировании зон покрытия. Для дополнительной проверки предложенного подхода были проведены сравнительные эксперименты, в ходе которых изучалась зависимость коэффициента охвата от числа формируемых лучей. Результаты экспериментов (рис. 5) показывают, что увеличение числа лучей существенно влияет на охват абонентов.

1. При использовании одного луча коэффициент охвата составил 52 %, что указывает на недостаточное покрытие и неспособность охватить распределенные группы абонентов.


2. При формировании двух лучей значение коэффициента покрытия увеличилось до 71 %, что дает заметное улучшение охвата абонентов, однако значительная доля объектов остается вне зон покрытия.

3. Применение трех лучей позволило достичь коэффициента покрытия 88 %, обеспечив более равномерное распределение зон покрытия.

4. При использовании четырех лучей наблюдается дальнейшее улучшение, и коэффициент охвата достигает 96 %, что говорит о почти полном покрытии динамически перемещающихся абонентов.



■ **Рис. 4.** Примеры создания кластеров
■ **Fig. 4.** Examples of creating clusters



■ **Рис. 5.** Зависимость coverage ratio от числа лучей

■ **Fig. 5.** The dependence of the coverage ratio on the number of beams

5. Применение пяти лучей привело к полному охвату (100 %), что демонстрирует потенциал метода при оптимальной конфигурации.

Первоначально при увеличении числа лучей наблюдается значительный прирост коэффициента покрытия. Однако при достижении пяти лучей отмечается эффект насыщения, когда дальнейшее увеличение числа лучей не приводит к улучшению охвата. Несмотря на то, что среднее число абонентов в зоне работы РИП равно шести (а максимальное девяти), уже четыре луча обеспечивают практически полное покрытие. Это связано с тем, что соседние абоненты часто попадают в один кластер и обслуживаются одним лучом. По мере дальнейшего роста количества абонентов вероятность попадания нескольких абонентов в один кластер только растет. Однако при определении оптимального количества лучей надо также иметь в виду, что для пассивных РИП мощность переотраженного сигнала БС делится между лучами поровну, снижая мощность принятого абонентом сигнала. Это свидетельствует о том, что оптимальное число лучей определяется компромиссным соотношением между максимальным охватом и другими параметрами системы. Использование нескольких лучей позволяет гибко реагировать на изменения в плотности распределения абонентов. При динамическом перемещении объектов метод демонстрирует высокую адаптивность, обеспечивая своевременное корректирование зон покрытия, что критически важно для поддержания качества связи в условиях реального времени. Полученные результаты указывают на то, что применение мультилучевого формирования зон покрытия является эффективным решением для систем с РИП. В зависимости от требований конкретного сценария (например, уровня загруженности, динамики перемещений абонентов) возможно оптимальное

распределение числа лучей, что позволяет достигать баланса между качеством связи и вычислительными затратами.

Проведенный анализ дает возможность сделать вывод, что интеграция методов компьютерного зрения и кластеризации существенно повышает эффективность использования зон покрытия в динамичных условиях. Использование нескольких лучей обеспечивает практически полный охват абонентов, что ведет к повышению качества связи и эффективному использованию энергетического бюджета системы. Дальнейшие исследования могут быть направлены на оптимизацию вычислительных процессов при увеличении числа лучей, а также на оценку влияния окружающей среды и плотности абонентов на параметры формирования зон покрытия.

Заключение

В работе были исследованы возможности использования систем компьютерного зрения для оптимизации управления положением луча РИП в системах связи ММ-диапазона. Проведено моделирование зон покрытия (областей с уровнем сигнала, достаточным для работы абонентского оборудования) РИП ММ-диапазона с узкой ДН, получены приближенные формулы для оценки размеров и ориентации зон покрытия для различных положений луча. Полученные данные использованы для определения требований к специализированным алгоритмам кластеризации, которые объединяют потенциальных абонентов в группы оптимальных размеров и формы. Показано, как информация о количестве и расположении кластеров может быть использована для управления фазами элементов РИП. Проведена проверка предлагаемых подходов на реальных видеоматериалах с пешеходами, произвольно перемещающимися в зоне действия РИП. Для обнаружения пешеходов использовалась современная сверточная нейронная сеть YOLOv11, обеспечивающая высокую точность и скорость работы при умеренной вычислительной сложности. После обнаружения объектов применяется метод кластеризации DBSCAN для группировки пользователей. В качестве метрики оценки качества связи использовался коэффициент покрытия (coverage ratio). Показаны преимущества использования многолучевого режима работы РИП в случае большого количества абонентов. Получены количественные оценки зависимости коэффициента покрытия от количества лучей в реальных ситуациях. Эти зависимости показывают, что увеличение количества одновременно формируемых лучей до трех-четырех существенно повышает коэффициент покрытия и дальнейшее увеличение количества лучей обычно нецелесообразно.

Литература

1. Ahn Y., Kim J., Kim S., Kim S., Shim B. Sensing and computer vision-aided mobility management for 6G millimeter and terahertz communication systems. *IEEE Transactions on Communications*, 2024, vol. 72, iss. 10, pp. 6044–6058. doi:10.1109/TCOMM.2024.3392799
2. Loscri V., Rizza C., Benslimane A., Vegni A. M., Innocenti E., Giuliano R. BEST-RIM: A mmWave beam steering approach based on computer vision-enhanced reconfigurable intelligent metasurfaces. *IEEE Transactions on Vehicular Technology*, 2023, vol. 72, iss. 6, pp. 7613–7626. doi:10.1109/TVT.2023.3243358
3. Loscri V., Vegni A. M., Innocenti E., Giuliano R., Mazzenga F. A joint computer vision and reconfigurable intelligent meta-surface approach for interference reduction in beyond 5G networks. *IEEE 22nd International Conference on High Performance Switching and Routing (HPSR)*, Paris, France, 7–10 June 2021, IEEE, 2021, pp. 1–6. doi:10.1109/HPSR52026.2021.9481794
4. Tian Y., Pan G., Alouini M. S. Applying deep-learning-based computer vision to wireless communications: Methodologies, opportunities, and challenges. *IEEE Open Journal of the Communications Society*, 2021, vol. 2, pp. 132–143. doi:10.1109/OJCOMS.2020.3042630
5. Alrabeiah M., Hredzak A., Liu Z., Alkhateeb A. ViWi: A deep learning dataset framework for vision-aided wireless communications. *IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*, Antwerp, Belgium, 25–28 May 2020, IEEE, 2020, pp. 1–5. doi:10.1109/VTC2020-Spring48590.2020.9128579
6. Jiang S., Hindy A., Alkhateeb A. Camera aided reconfigurable intelligent surfaces: Computer vision based fast beam selection. *IEEE International Conference on Communications*, Rome, Italy, 28 May–01 June 2023, IEEE, 2023, pp. 2921–2926. doi:10.1109/ICC45041.2023.10279112
7. Ouyang M., Gao F., Wang Y., Zhang S., Li P., Ren J. Computer vision-aided reconfigurable intelligent surface-based beam tracking: Prototyping and experimental results. *IEEE Transactions on Wireless Communications*, 2023, vol. 22, iss. 12, pp. 8681–8693. doi:10.1109/TWC.2023.3264752
8. Pavlov V. A., Belov A. A., Sayanskiy A. D., Vabishchevich D. A. Reconfigurable intelligent surface assisted by computer vision for increasing coverage area in mobile communication systems. *Photonics and Nanostructures – Fundamentals and Applications*, 2024, vol. 62, Article 101318. doi:10.1016/j.photonics.2024.101318
9. Павлов В. А., Белов А. А., Завьялов С. В., Саянский А. Д., Вабищевич Д. А. Применение компьютерного зрения для управления реконфигурируемой интеллектуальной поверхностью с целью расширения зоны покрытия в системах мобильной связи. *Т-Сотт: Телекоммуникации и транспорт*, 2024, т. 18, № 9, с. 28–35. doi:10.36724/2072-8735-2024-18-9-28-35
10. Sayanskiy A., Yafasov R., Pavlov V., Belov A. Application of computer vision to intelligent reflective surface beam steering. *Sixteenth International Congress on Artificial Materials for Novel Wave Phenomena (Metamaterials)*, Siena, Italy, 12–17 September 2022, 2022, pp. X-391–X-393. doi:10.1109/Metamaterials54993.2022.9920826
11. Kim S., Ahn Y., Park D., Shim B. VOMTC: Vision objects for millimeter and terahertz communications. *IEEE Transactions on Cognitive Communications and Networking*, 2025, vol. 11, iss. 1, pp. 243–257. doi:10.1109/TCCN.2024.3435909
12. Liu Y., Wu J., Kim S., Shim B. Vision-aided blockage prediction and proactive handover for indoor mmWave and terahertz communications. *IEEE Global Communications Conference*, Kuala Lumpur, Malaysia, 4–8 December 2023, IEEE, 2023, pp. 7411–7416. doi:10.1109/GLOBECOM54140.2023.10437782
13. Li W., Ma Q., Liu C., Zhang Y., Wu X., Wang J., Gao S., Qiu T., Liu T., Xiao Q., Wei J., Gu T. T., Zhou Z., Li F., Cheng Q., Li L., Tang W., Cui T. J. Intelligent metasurface system for automatic tracking of moving targets and wireless communications based on computer vision. *Nature Communications*, 2023, vol. 14, no. 989. doi:10.1038/s41467-023-36645-3
14. Wang C. Y., Bochkovskiy A., Liao H. Y. M. Scaled-YOLOv4: Scaling Cross Stage Partial Network. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2, 2021, pp. 13024–13033. doi:10.1109/CVPR46437.2021.01283
15. Bewley A., Ge Z., Ott L., Ramos F., Upcroft B. Simple online and realtime tracking. *IEEE International Conference on Image Processing (ICIP)*, Phoenix, AZ, USA, 25–28 September 2016, IEEE, 2016, pp. 3464–3468. doi:10.1109/ICIP.2016.7533003
16. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 27–30 June 2016, IEEE, 2016, pp. 770–778. doi:10.1109/CVPR.2016.90
17. Ahn Y., Kim J., Kim S., Shim K., Kim J., Kim S. Toward intelligent millimeter and terahertz communication for 6G: Computer vision-aided beamforming. *IEEE Wireless Communications*, 2023, vol. 30, iss. 5, pp. 179–186. doi:10.1109/MWC.007.2200155
18. Semenov S., Pavlov V., Belov A. Application of genetic algorithm to optimize coverage in shadow regions in 5G and 6G millimeter wave communication systems. *26th International Conference on Digital Signal Processing and its Applications (DSPA)*, 2024, pp. 1–4. doi:10.1109/DSPA60853.2024.10510148
19. Amjoud A. B., Amrouch M. Object detection using deep learning, CNNs and vision transformers: A review. *IEEE Access*, 2023, vol. 11, pp. 35479–35516. doi:10.1109/ACCESS.2023.3266093

20. Khanam R., Hussain M. YOLOv11: An Overview of the Key Architectural Enhancements. *arXiv*, 2024, <https://arxiv.org/html/2410.17725v1> (дата обращения: 3.03.2025).

21. Хансен Р. С. Фазированные антенные решетки: пер. с англ. под ред. А. И. Синани. 2-е изд. М., Технофера, 2012. 560 с.

UDC 004.932.72

doi:10.31799/1684-8853-2025-3-59-68

EDN: UTJUH

Clustering of users in cognitive control system of reflective intelligent surface for 5G/6G communication systems

V. A. Pavlov^a, PhD, Tech., Associate Professor, orcid.org/0000-0003-0726-6613, pavlov_va@spbstu.ru

A. A. Belov^a, Leading Engineer, orcid.org/0000-0003-0617-4514

F. Shariaty^a, Post-Graduate Student, Assistant Professor, orcid.org/0000-0002-7060-8826

^aPeter the Great St. Petersburg Polytechnic University, 29, Politekhnicheskaya St., 195251, Saint-Petersburg, Russian Federation

Introduction: Improving the efficiency of millimeter-wave communication systems is an important task in the field of telecommunications. The use of computer vision assisted systems to improve beam control of reconfigurable intelligent surfaces is of significant interest in the development of 5G/6G millimeter wave systems. **Purpose:** To develop and test the methods that make it possible to accurately determine the position of subscribers and optimize beamforming in millimeter-wave communication systems. **Methods:** We model the coverage areas of a reconfigurable intelligent surface to assess their size and orientation. Approximate formulas are derived for the shape and size of the coverage areas. We use the YOLOv11 convolutional neural network to detect pedestrians, and the DBSCAN clustering method to group nearby users. The quality of communication is assessed using the coverage ratio metric (the ratio of the number of users served by the system to all users). **Results:** We perform a simulation of a millimeter wave communication system. The simulation shows that the coverage area of one beam has the shape of an elongated ellipse, the dimensions of which depend on the position of the intersection point of the maximum radiation of an antenna with the ground surface. Testing on real video materials confirms the effectiveness of the proposed methods. In particular, the use of multibeam mode of operation of a reconfigurable intelligent surface has shown advantages in the case of a large number of users. Quantitative estimates show that the optimal number of beams usually does not exceed four. **Practical relevance:** The research results are of significant practical importance for the development and optimization of millimeter-wave communication systems. The proposed methods make it possible to increase the efficiency of beam control and improve the quality of communication with a large number of subscribers.

Keywords — computer vision, reconfigurable intelligent surface, clustering, object detection, 5G/6G communication systems, mobile communications.

For citation: Pavlov V. A., Belov A. A., Shariaty F. Clustering of users in cognitive control system of reflective intelligent surface for 5G/6G communication systems. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2025, no. 3, pp. 59–68 (In Russian). doi:10.31799/1684-8853-2025-3-59-68, EDN: UTJUH

References

1. Ahn Y., Kim J., Kim S., Kim S., Shim B. Sensing and computer vision-aided mobility management for 6G millimeter and terahertz communication systems. *IEEE Transactions on Communications*, 2024, vol. 72, iss. 10, pp. 6044–6058. doi:10.1109/TCOMM.2024.3392799
2. Loscri V., Rizza C., Benslimane A., Vegni A. M., Innocenti E., Giuliano R. BEST-RIM: A mmWave beam steering approach based on computer vision-enhanced reconfigurable intelligent metasurfaces. *IEEE Transactions on Vehicular Technology*, 2023, vol. 72, iss. 6, pp. 7613–7626. doi:10.1109/TVT.2023.3243358
3. Loscri V., Vegni A. M., Innocenti E., Giuliano R., Mazzenga F. A joint computer vision and reconfigurable intelligent meta-surface approach for interference reduction in beyond 5G networks. *IEEE 22nd International Conference on High Performance Switching and Routing (HPSR)*, IEEE, 2021, pp. 1–6. doi:10.1109/HPSR52026.2021.9481794
4. Tian Y., Pan G., Alouini M. S. Applying deep-learning-based computer vision to wireless communications: Methodologies, opportunities, and challenges. *IEEE Open Journal of the Communications Society*, 2021, vol. 2, pp. 132–143. doi:10.1109/OJCOMS.2020.3042630
5. Alrabeiah M., Hredzak A., Liu Z., Alkhateeb A. ViWi: A deep learning dataset framework for vision-aided wireless communications. *IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*, IEEE, 2020, pp. 1–5. doi:10.1109/VTC2020-Spring48590.2020.9128579
6. Jiang S., Hindy A., Alkhateeb A. Camera aided reconfigurable intelligent surfaces: Computer vision based fast beam selection. *IEEE International Conference on Communications*, IEEE, 2023, pp. 2921–2926. doi:10.1109/ICC45041.2023.10279112
7. Ouyang M., Gao F., Wang Y., Zhang S., Li P., Ren J. Computer vision-aided reconfigurable intelligent surface-based beam tracking: Prototyping and experimental results. *IEEE Transactions on Wireless Communications*, 2023, vol. 22, iss. 12, pp. 8681–8693. doi:10.1109/TWC.2023.3264752
8. Pavlov V. A., Belov A. A., Sayanskiy A. D., Vabishchevich D. A. Reconfigurable intelligent surface assisted by computer vision for increasing coverage area in mobile communication systems. *Photonics and Nanostructures – Fundamentals and Applications*, 2024, vol. 62, Article 101318. doi:10.1016/j.photonics.2024.101318
9. Pavlov V. A., Belov A. A., Zavjalov S. V., Sayanskiy A. D., Vabishchevich D. A. Application of computer vision to control reconfigurable intelligent surface to extend coverage area in mobile communication systems. *T-Comm*, 2024, vol. 18, no. 9, pp. 28–35 (In Russian). doi:10.36724/2072-8735-2024-18-9-28-35
10. Sayanskiy A., Yafasov R., Pavlov V., Belov A. Application of computer vision to intelligent reflective surface beam steering. *Sixteenth International Congress on Artificial Materials for Novel Wave Phenomena (Metamaterials)*, 2022, pp. X-391–X-393. doi:10.1109/Metamaterials54993.2022.9920826
11. Kim S., Ahn Y., Park D., Shim B. VOMTC: Vision objects for millimeter and terahertz communications. *IEEE Transactions on Cognitive Communications and Networking*, 2025, vol. 11, iss. 1, pp. 243–257. doi:10.1109/TCCN.2024.3435909
12. Liu Y., Wu J., Kim S., Shim B. Vision-aided blockage prediction and proactive handover for indoor mmWave and terahertz communications. *IEEE Global Communications Conference*, IEEE, 2023, pp. 7411–7416. doi:10.1109/GLOBE-COM54140.2023.10437782

13. Li W., Ma Q., Liu C., Zhang Y., Wu X., Wang J., Gao S., Qiu T., Liu T., Xiao Q., Wei J., Gu T. T., Zhou Z., Li F., Cheng Q., Li L., Tang W., Cui T. J. Intelligent metasurface system for automatic tracking of moving targets and wireless communications based on computer vision. *Nature Communications*, 2023, vol. 14, no. 989. doi:10.1038/s41467-023-36645-3
14. Wang C. Y., Bochkovskiy A., Liao H. Y. M. Scaled-YOLOv4: Scaling cross stage partial network. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021, pp. 13024–13033. doi:10.1109/CVPR46437.2021.01283
15. Bewley A., Ge Z., Ott L., Ramos F., Upcroft B. Simple online and realtime tracking. *IEEE International Conference on Image Processing (ICIP)*, IEEE, 2016, pp. 3464–3468. doi:10.1109/ICIP.2016.7533003
16. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2016, pp. 770–778. doi:10.1109/CVPR.2016.90
17. Ahn Y., Kim J., Kim S., Shim K., Kim J., Kim S. Toward intelligent millimeter and terahertz communication for 6G: Computer vision-aided beamforming. *IEEE Wireless Communications*, 2023, vol. 30, iss. 5, pp. 179–186. doi:10.1109/MWC.007.2200155
18. Semenov S., Pavlov V., Belov A. Application of genetic algorithm to optimize coverage in shadow regions in 5G and 6G millimeter wave communication systems. *26th International Conference on Digital Signal Processing and its Applications (DSPA)*, 2024, pp. 1–4. doi:10.1109/DSPA60853.2024.10510148
19. Amjoud A. B., Amrouch M. Object detection using deep learning, CNNs and vision transformers: A review. *IEEE Access*, 2023, vol. 11, pp. 35479–35516. doi:10.1109/ACCESS.2023.3266093
20. Khanam R., Hussain M. YOLOv11: An overview of the key architectural enhancements. *arXiv*, 2024. Available at: <https://arxiv.org/html/2410.17725v1> (accessed 3 March 2025).
21. Hansen R. C. *Fazirovannyye antennoye reshethki* [Phased Array Antennas]. 2nd ed. Moscow, Tekhnosfera Publ., 2012. 560 p. (In Russian).

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 комментарии 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;

— экспортное 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

Памяти Николая Алексеевича Балонина

10.06.2025 ушел из жизни наш друг и постоянный автор журнала Николай Алексеевич Балонин.

Николай Алексеевич Балонин родился в Вологодской области. В 1976 году приехал в Ленинград и поступил в Ленинградский электротехнический институт им. В. И. Ульянова (Ленина). После окончания ЛЭТИ преподавал в учебном заведении в Новгороде.

В Санкт-Петербургском государственном университете аэрокосмического приборостроения (ГУАП) работал более 35 лет. Здесь, окончив аспирантуру, защитил диссертацию на соискание ученой степени кандидата технических наук.

Преподавал ряд дисциплин, связанных с системами управления, моделированием, сетевым программированием, руководил научными исследованиями магистрантов и аспирантов.

Без отрыва от преподавательской работы защитил докторскую диссертацию, продолжив работу на кафедре вычислительных систем и сетей.

С 2008 года Н. А. Балонин руководил лабораторией глобально-распределенных информационно-управляющих систем, в которой под его руководством в кооперации с коллективами других университетов выполнено большое количество проектов, основанных на полученных научных результатах.

Николай Алексеевич был ученым с широким спектром научных интересов. Ему принадлежат признанные научные результаты в области систем управления, идентифицируемости стационарных и нестационарных динамических систем. Его многочисленными трудами существенно развита и обогащена теория ортогональных и квазиортогональных матриц, усовершенствованы методы преобразований информации с их использованием. Именно эти труды были отмечены международным научным сообществом как не имеющие аналогов и явились основой, привлекая выдающихся ученых из Австралии, Германии, Канады, Израиля, Греции и других стран к работе в объединенном научном коллективе под его руководством.

Николай Алексеевич является автором пяти монографий и более 100 научных статей. Для учебного процесса им изданы десятки учебных пособий.

Много сил отдавал Николай Алексеевич подготовке квалифицированных инженеров, привлекая их к научным разработкам и воспитывая ответственными исследователями.

Смерть Николая Алексеевича – большое личное горе для каждого из нас, невосполнимая утрата для нашего научного коллектива. Светлая память о нем останется в наших сердцах навсегда.



*Коллектив Института информационных технологий и программирования,
редакция журнала «Информационно-управляющие системы»,
кафедра вычислительных систем и сетей ГУАП,
prof. Jennifer Seberry (Австралия),
prof. Nathan Blaunstein (Израиль),
проф. М. Б. Сергеев,
проф. Т. М. Татарникова,
проф. А. П. Шепета,
доц. В. Р. Клюковкин,
доц. А. А. Востриков,
доц. А. М. Сергеев,
науч. сотрудник Д. В. Куртяник,
науч. сотрудник Е. К. Григорьев*

**АЛПАТОВА
Марианна
Валерьевна**



Доцент кафедры прикладной математики МИРЭА – Российского технологического университета, Москва.

В 2018 году окончила Московский политехнический университет по специальности «Информатика и вычислительная техника».

В 2024 году защитила диссертацию на соискание ученой степени кандидата технических наук. Является автором 11 научных публикаций.

Область научных интересов – дополненная реальность, виртуальная реальность, смешанная реальность, метавселенная, алгоритмы пространственного позиционирования, анализ пользовательского опыта в XR.

Эл. адрес:

m.v.alpatova@yandex.ru

**ВЕРЗУН
Наталья
Аркадьевна**



Доцент кафедры информационных систем и технологий Санкт-Петербургского государственного экономического университета и кафедры информационных систем Санкт-Петербургского государственного электротехнического университета «ЛЭТИ».

В 1993 году окончила Ленинградский электротехнический институт связи им. проф. М. А. Бонч-Бруевича по специальности «Автоматическая электросвязь».

В 1999 году защитила диссертацию на соискание ученой степени кандидата технических наук. Является автором 100 научных публикаций.

Область научных интересов – математическое моделирование информационных систем множественного доступа.

Эл. адрес: verzun.n@unecon.ru

**ЛЕБЕДЕВ
Илья
Сергеевич**



Профессор, главный научный сотрудник Санкт-Петербургского Федерального исследовательского центра РАН.

В 1998 году окончил Санкт-Петербургское высшее военное училище ПВО по специальности «Инженер-математик».

В 2012 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором более 80 научных публикаций.

Область научных интересов – информационные технологии, машинное обучение, компьютерная лингвистика.

Эл. адрес: isl_box@mail.ru

**БЕЛОВ
Андрей
Александрович**



Ведущий инженер Высшей школы прикладной физики и космических технологий Института электроники и телекоммуникаций Санкт-Петербургского политехнического университета Петра Великого.

В 1989 году окончил Ленинградский политехнический институт им. М. И. Калинина по специальности «Радиофизика и электроника».

Является автором 30 научных публикаций и пяти патентов на изобретения.

Область научных интересов – обработка сигналов и изображений, СВЧ-электроника, радиолокация, дефектоскопия.

Эл. адрес: belov@spbstu.ru

**КОЛБАНЕВ
Михаил
Олегович**



Профессор кафедры информационных систем и технологий Санкт-Петербургского государственного экономического университета и кафедры информационных систем Санкт-Петербургского государственного электротехнического университета «ЛЭТИ». Мастер связи.

В 1977 году окончил Ленинградский электротехнический институт связи им. проф. М. А. Бонч-Бруевича по специальности «Автоматическая электросвязь».

В 2004 году защитил диссертацию на соискание ученой степени доктора технических наук. Является автором более 200 научных публикаций.

Область научных интересов – информатика, телекоммуникации, цифровая экономика, моделирование информационных систем.

Эл. адрес: mokolbanov@mail.ru

**ЛОСЕВ
Александр
Георгиевич**



Профессор, директор Института математики и информационных технологий Волгоградского государственного университета, заслуженный работник высшей школы РФ, почетный работник высшего профессионального образования РФ.

В 1986 году окончил Волгоградский государственный университет по специальности «Математика».

В 2001 году защитил диссертацию на соискание ученой степени доктора физико-математических наук.

Является автором 190 научных публикаций.

Область научных интересов – искусственный интеллект, интеллектуальный анализ данных, математическое моделирование, эллиптические уравнения на римановых многообразиях.

Эл. адрес: alexander.losev@volsu.ru

**МЕДВЕДЕВ
Иван
Андреевич**



Аспирант кафедры математического анализа и теории функций Волгоградского государственного университета.
В 2024 году окончил магистратуру Волгоградского государственного университета по специальности «Прикладная математика и информатика».
Является автором восьми научных публикаций.
Область научных интересов — искусственный интеллект, математическое моделирование, методы анализа данных.
Эл. адрес: medvedevia@volsu.ru

**МИКОВ
Александр
Александрович**



Преподаватель кафедры информационных технологий Кубанского государственного университета, Краснодар.
В 2023 году окончил Кубанский государственный университет по направлению «Математическое обеспечение и администрирование информационных систем».
Является автором 19 научных публикаций.
Область научных интересов — теория компьютерных сетей, методы проектирования систем имитационного моделирования, системы массового обслуживания.
Эл. адрес: a.a.mikov@mail.ru

**МИКОВ
Александр
Иванович**



Профессор кафедры информационных технологий Кубанского государственного университета, Краснодар.
В 1971 году окончил Пермский политехнический институт по специальности «Автоматика и телемеханика».
В 1989 году защитил диссертацию на соискание ученой степени доктора физико-математических наук.
Является автором 225 научных публикаций.
Область научных интересов — теория компьютерных сетей, методы проектирования систем имитационного моделирования, системы массового обслуживания.
Эл. адрес: alexander_mikov@mail.ru

**ПАВЛОВ
Виталий
Александрович**



Доцент Высшей школы прикладной физики и космических технологий Института электроники и телекоммуникаций Санкт-Петербургского политехнического университета Петра Великого.
В 2012 году окончил Санкт-Петербургский государственный политехнический университет по специальности «Защищенные системы связи».
В 2020 году защитил диссертацию на соискание ученой степени кандидата технических наук.
Является автором 40 научных публикаций.
Область научных интересов — обработка сигналов, обработка изображений, компьютерное зрение, машинное обучение, глубокое обучение.
Эл. адрес: pavlov_va@spbstu.ru

**РУДЯК
Юрий
Владимирович**



Профессор кафедры информатики и информационных технологий Московского политехнического университета.
В 1976 году окончил Московский государственный университет им. М. В. Ломоносова по специальности «Физика».
В 1996 году защитил диссертацию на соискание ученой степени доктора физико-математических наук.
Является автором 78 научных публикаций.
Область научных интересов — прикладная математика, численные методы, алгоритмы, базы данных.
Эл. адрес: rudyak@mail.ru

**САЛИЕВА
Аделина
Рустамовна**



Аспирант кафедры информационных систем Санкт-Петербургского государственного электротехнического университета «ЛЭТИ».
В 2021 году окончила Кыргызский государственный технический университет им. И. Раззакова по специальности «Логистика», в 2023 году — Национальный исследовательский ядерный университет «МИФИ» по специальности «Информатика и вычислительная техника».
Является автором десяти научных публикаций.
Область научных интересов — искусственный интеллект, логистика и системный анализ.
Эл. адрес: rustamovna.a3@gmail.com

**ШАРИАТИ
Фаридоддин**

Ассистент Высшей школы прикладной физики и космических технологий Института электроники и телекоммуникаций Санкт-Петербургского политехнического университета Петра Великого.

В 2021 году окончил Санкт-Петербургский политехнический университет Петра Великого по специальности «Инфокоммуникационные технологии и системы связи».

Является автором 35 научных публикаций.

Область научных интересов — искусственный интеллект в медицине, обработка медицинских изображений, автоматизированные системы диагностики.

Эл. адрес: shariati_f@spbstu.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.
