

ISSN 2713-3192
DOI 10.15622/ia.2025.24.3
<http://ia.spcras.ru>

ТОМ 24 № 3

ИНФОРМАТИКА
И АВТОМАТИЗАЦИЯ

INFORMATICS
AND AUTOMATION



СПб ФИЦ РАН

Санкт-Петербург
2025



INFORMATICS AND AUTOMATION

Volume 24 № 3, 2025

Scientific and educational journal primarily specialized in computer science, automation, robotics, applied mathematics, interdisciplinary research

Founded in 2002

Founder and Publisher

St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS)

Editor-in-Chief

A. L. Ronzhin, Prof., Dr. Sci., St. Petersburg, Russia

Editorial Council

A. A. Ashimov	Prof., Dr. Sci., Academician of the National Academy of Sciences of the Republic of Kazakhstan, Almaty, Kazakhstan
I. A. Kalyaev	Prof., Dr. Sci., Academician of RAS, Taganrog, Russia
Yu. A. Merkuryev	Prof., Dr. Sci., Academician of the Latvian Academy of Sciences, Riga, Latvia
A. I. Rudskoi	Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia
V. Sgurev	Prof., Dr. Sci., Academician of the Bulgarian Academy of Sciences, Sofia, Bulgaria
B. Ya. Sovetov	Prof., Dr. Sci., Academician of RAE, St. Petersburg, Russia
V. A. Soyfer	Prof., Dr. Sci., Academician of RAS, Samara, Russia

Editorial Board

E. Azarov	Prof., Dr. Sci., Minsk, Belarus
O. Yu. Gusikhin	Ph. D., Dearborn, USA
V. Delic	Prof., Dr. Sci., Novi Sad, Serbia
A. Dolgui	Prof., Dr. Sci., St. Etienne, France
M. N. Favorskaya	Prof., Dr. Sci., Krasnoyarsk, Russia
M. Zelezny	Assoc. Prof., Ph.D., Plzen, Czech Republic
H. Kaya	Assoc. Prof., Ph.D., Utrecht, Netherlands
A. A. Karpov	Assoc. Prof., Dr. Sci., St. Petersburg, Russia
S. V. Kuleshov	Dr. Sci., St. Petersburg, Russia
A. D. Khomonenko	Prof., Dr. Sci., St. Petersburg, Russia
D. A. Ivanov	Prof., Dr. Habil., Berlin, Germany
K. P. Markov	Assoc. Prof., Ph.D., Aizu, Japan
R. V. Meshcheryakov	Prof., Dr. Sci., Moscow, Russia
N. A. Moldovian	Prof., Dr. Sci., St. Petersburg, Russia
V. V. Nikulin	Prof., Ph.D., New York, United States
V. Yu. Osipov	Prof., Dr. Sci., Deputy Editor-in-Chief, St. Petersburg, Russia
V. K. Pshikhopov	Prof., Dr. Sci., Taganrog, Russia
H. Samani	Assoc. Prof., Ph.D., Plymouth, UK
J. Savage	Assoc. Prof., Ph.D., Mexico City, Mexico
M. Secujski	Assoc. Prof., Ph.D., Novi Sad, Serbia
A. V. Smirnov	Prof., Dr. Sci., St. Petersburg, Russia
B. V. Sokolov	Prof., Dr. Sci., St. Petersburg, Russia
L. V. Utkin	Prof., Dr. Sci., St. Petersburg, Russia
L. B. Sheremetov	Assoc. Prof., Dr. Sci., Mexico, Mexico

Editor: A. S. Viktorova

Interpreter: Ya. N. Berezina

Art editor: N. A. Dormidontova

Editorial office address

SPC RAS, 39 litera A, 14-th line V.O., St. Petersburg, 199178, Russia

e-mail: ia@spcras.ru, web: <http://ia.spcras.ru>

The journal is indexed in Scopus

The journal is published under the scientific-methodological supervision of Department for Nanotechnologies and Information Technologies of the Russian Academy of Sciences

© St. Petersburg Federal Research Center of the Russian Academy of Sciences, 2025

ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

Том 24 № 3, 2025

Научный, научно-образовательный журнал с базовой специализацией
в области информатики, автоматизации, робототехники, прикладной математики
и междисциплинарных исследований.

Журнал основан в 2002 году

Учредитель и издатель

Федеральное государственное бюджетное учреждение науки
«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук»
(СПб ФИЦ РАН)

Главный редактор

А. Л. Ронжин, д-р техн. наук, проф., Санкт-Петербург, РФ

Редакционный совет

А. А. Ашимов	академик Национальной академии наук Республики Казахстан, д-р техн. наук, проф., Алматы, Казахстан
И. А. Каляев	академик РАН, д-р техн. наук, проф., Таганрог, РФ
Ю. А. Меркурьев	академик Латвийской академии наук, д-р, проф., Рига, Латвия
А. И. Рудской	академик РАН, д-р техн. наук, проф., Санкт-Петербург, РФ
В. Сгурев	академик Болгарской академии наук, д-р техн. наук, проф., София, Болгария
Б. Я. Советов	академик РАО, д-р техн. наук, проф., Санкт-Петербург, РФ
В. А. Соифер	академик РАН, д-р техн. наук, проф., Самара, РФ

Редакционная коллегия

И. С. Азаров	д-р техн. наук, проф., Минск, Беларусь
О. Ю. Гусихин	д-р наук, Диаборн, США
В. Делич	д-р техн. наук, проф., Нови-Сад, Сербия
А. Б. Долгий	д-р наук, проф. Сент-Этьен, Франция
М. Железны	д-р наук, доцент, Пльзень, Чешская республика
Д. А. Иванов	д-р экон. наук, проф., Берлин, Германия
Х. Кайя	д-р наук, доцент, Утрехт, Нидерланды
А. А. Карпов	д-р техн. наук, доцент, Санкт-Петербург, РФ
С. В. Кулешов	д-р техн. наук, Санкт-Петербург, РФ
К. П. Марков	д-р наук, доцент, Аизу, Япония
Р. В. Мещеряков	д-р техн. наук, проф., Москва, РФ
Н. А. Молдовян	д-р техн. наук, проф., Санкт-Петербург, РФ
В. В. Никулин	д-р наук, проф., Нью-Йорк, США
В. Ю. Осипов	д-р техн. наук, проф., зам. главного редактора, Санкт-Петербург, РФ
В. Х. Пшихопов	д-р техн. наук, проф., Таганрог, РФ
Х. К. Саваж	д-р техн. наук, доцент, Мехико, Мексика
Х. Самани	д-р наук, доцент, Плимут, Соединенное Королевство
М. Сечуйски	д-р техн. наук, доцент, Нови-Сад, Сербия
А. В. Смирнов	д-р техн. наук, проф., Санкт-Петербург, РФ
Б. В. Соколов	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. В. Уткин	д-р техн. наук, проф., Санкт-Петербург, РФ
М. Н. Фаворская	д-р техн. наук, проф., Красноярск, РФ
А. Д. Хомоненко	д-р техн. наук, проф., Санкт-Петербург, РФ
Л. Б. Шереметов	д-р техн. наук, Мехико, Мексика

Выпускающий редактор: А. С. Викторова

Переводчик: Я. Н. Березина

Художественный редактор: Н. А. Дормидонтова

Адрес редакции

14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

e-mail: ia@spcras.ru, сайт: <http://ia.spcras.ru>

Журнал индексируется в международной базе данных Scopus

Журнал входит в «Перечень ведущих рецензируемых научных журналов и изданий, в которых должны быть опубликованы основные научные результаты диссертации на соискание ученой степени доктора и кандидата наук»

Журнал выпускается при научно-методическом руководстве Отделения нанотехнологий и информационных технологий Российской академии наук

© Федеральное государственное бюджетное учреждение науки

«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук», 2025
Разрешается воспроизведение в прессе, а также сообщение в эфир или по кабелю опубликованных в составе печатного периодического издания - журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ» статей по текущим экономическим, политическим, социальным и религиозным вопросам с обязательным указанием имени автора статьи и печатного периодического издания журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ»

CONTENTS

Robotics, Automation and Control Systems

M. Medvedev, V. Pshikhopov, I. Evdokimov
A ROBUST CONTROL ALGORITHM FOR SINGLE INPUT SINGLE OUTPUT
DYNAMIC OBJECT BASED ON TABLE-BASED Q-METHOD OF REINFORCEMENT
LEARNING 717

A. Antipov, Ju. Kokunko, D. Wolf, A. Shirokov
SYNTHESIS OF COMBINED QUADROCOPTER ATTITUDE AND ALTITUDE
CONTROL BASED ON BLOCK APPROACH WITH SIGMOIDAL FEEDBACKS 745

A. Rodionov, T. Matkurbanov
PLANNING UAV FLIGHT TRAJECTORIES FOR MONITORING LARGE AREAS 791

S.P. Pawale, P.G. Patil
A COMPREHENSIVE ANALYSIS OF MULTI-CHANNEL MAC AND CLUSTERING
PROTOCOLS FOR ROBUST AND ENERGY-EFFICIENT WIRELESS SENSOR
NETWORKS 828

C.N. Anh, T.B. Thao, T.B. Hung, T.T. Huong, N.V. Hung
OPTIMIZING TRANSPORTATION COSTS: ENHANCING LOGISTICS EFFICIENCY
AND RESOURCE UTILIZATION IN DYNAMIC ENVIRONMENTS 856

A. Migranov
MODIFIED HEURISTIC TASK ALLOCATION ALGORITHMS FOR MOBILE ROBOT
TEAMS UNDER UNCERTAINTY 884

Mathematical Modeling and Applied Mathematics

V. Bogatyrev, V. Phung
AN APPROXIMATE ASSESSMENT OF LATENCY IN A COMPUTER SYSTEM WITH
CONTAINER VIRTUALIZATION 914

I. Bychkov, A. Feoktistov, M. Voskoboinikov, A. Edelev, N. Beresneva, O. Edeleva
OPTIMIZATION OF INTEGRATED ENERGY SYSTEM RESILIENCE 951

M. Idrissi Alami, A. Ez-zahout, F. Omary
COMPARATIVE STUDY OF PERSON RE-IDENTIFICATION TECHNIQUES BASED
ON DEEP LEARNING MODELS 982

СОДЕРЖАНИЕ

Робототехника, автоматизация и системы управления

М.Ю. Медведев, В.Х. Пшихопов, И.Д. Евдокимов
АЛГОРИТМ РОБАСТНОГО УПРАВЛЕНИЯ ОДНОМЕРНЫМ ДИНАМИЧЕСКИМ
ОБЪЕКТОМ НА ОСНОВЕ ТАБЛИЧНОГО Q-МЕТОДА ОБУЧЕНИЯ
С ПОДКРЕПЛЕНИЕМ 717

А.С. Антипов, Ю.Г. Кокунько, Д.А. Вольф, А.С. Широков
СИНТЕЗ КОМБИНИРОВАННОГО УПРАВЛЕНИЯ ОРИЕНТАЦИЕЙ И ВЫСОТОЙ
КВАДРОКОПТЕРА НА ОСНОВЕ БЛОЧНОГО ПОДХОДА С СИГМОВИДНЫМИ
ОБРАТНЫМИ СВЯЗЯМИ 745

А.С. Родионов, Т.А. Маткурбанов
ПЛАНИРОВАНИЕ ТРАЕКТОРИИ ПОЛЕТА БПЛА ПРИ МОНИТОРИНГЕ БОЛЬШОЙ
ОБЛАСТИ 791

С.П. Павале, П.Дж. Патил
КОМПЛЕКСНЫЙ АНАЛИЗ МНОГОКАНАЛЬНЫХ МАС-ПРОТОКОЛОВ
И КЛАСТЕРНЫХ ПРОТОКОЛОВ ДЛЯ СОЗДАНИЯ НАДЕЖНЫХ И
ЭНЕРГОЭФФЕКТИВНЫХ БЕСПРОВОДНЫХ СЕНСОРНЫХ СЕТЕЙ 828

К.Н. Ань, Т.Б. Тао, Т.Б. Хунг, Т.Т. Хуонг, Н.В. Хунг
ОПТИМИЗАЦИЯ ТРАНСПОРТНЫХ РАСХОДОВ: ПОВЫШЕНИЕ
ЭФФЕКТИВНОСТИ ЛОГИСТИКИ И ИСПОЛЬЗОВАНИЯ РЕСУРСОВ
В ДИНАМИЧЕСКОЙ СРЕДЕ 856

А.Б. Мигранов
МОДИФИЦИРОВАННЫЕ ЭВРИСТИЧЕСКИЕ АЛГОРИТМЫ РАСПРЕДЕЛЕНИЯ
ЗАДАНИЙ ДЛЯ ГРУПП МОБИЛЬНЫХ РОБОТОВ В УСЛОВИЯХ
НЕОПРЕДЕЛЕННОСТИ 884

Математическое моделирование и прикладная математика

В.А. Богатырев, В.К. Фунг
ПРИБЛИЖЕННАЯ ОЦЕНКА ЗАДЕРЖЕК В КОМПЬЮТЕРНОЙ СИСТЕМЕ
С КОНТЕЙНЕРНОЙ ВИРТУАЛИЗАЦИЕЙ 914

И.В. Бычков, А.Г. Феоктистов, М.Л. Воскобойников, А.В. Еделев, Н.М. Береснева,
О.А. Еделева
ОПТИМИЗАЦИЯ ЖИВУЧЕСТИ ЭНЕРГЕТИЧЕСКИХ КОМПЛЕКСОВ 951

М. Идрисси Алами, А. Эз-захут, Ф. Омари
СРАВНИТЕЛЬНОЕ ИССЛЕДОВАНИЕ МЕТОДОВ ПОВТОРНОЙ ИДЕНТИФИКАЦИИ
ЛИЧНОСТИ НА ОСНОВЕ МОДЕЛЕЙ ГЛУБОКОГО ОБУЧЕНИЯ 982

М.Ю. МЕДВЕДЕВ, В.Х. ПШИХОПОВ, И.Д. ЕВДОКИМОВ
**АЛГОРИТМ РОБАСТНОГО УПРАВЛЕНИЯ ОДНОМЕРНЫМ
ДИНАМИЧЕСКИМ ОБЪЕКТОМ НА ОСНОВЕ ТАБЛИЧНОГО
Q-МЕТОДА ОБУЧЕНИЯ С ПОДКРЕПЛЕНИЕМ**

Медведев М.Ю., Пшихопов В.Х., Евдокимов И.Д. Алгоритм робастного управления одномерным динамическим объектом на основе табличного Q-метода обучения с подкреплением.

Аннотация. В статье представлен обзор в области систем управления динамическими объектами на базе методов машинного обучения с подкреплением. На основе проведенного анализа сделан вывод о актуальности развития методов управления, базирующихся на обучении с подкреплением. В статье предлагается интеллектуальный алгоритм робастного управления устойчивыми динамическими объектами с одним входом и одним выходом, базирующийся на табличном Q-методе обучения нулевого порядка. Алгоритм осуществляет стабилизацию выходной величины объекта управления с заданной погрешностью, если параметры и внешние возмущения объекта являются кусочно-постоянными неизвестными величинами, а вектор состояния является измеряемым. Новизна предложенного алгоритма заключается в новом инкрементальном способе формирования управления, который позволяет, базируясь на множестве из трех возможных действий, стабилизировать объект управления. Предложенный способ формирования множества управляющих воздействий позволяет обеспечить требуемую точность стабилизации выхода объекта, изменяя амплитуду приращения управления. Также элементом новизны является предложенное выражения для расчета вознаграждения, которое позволяет ограничить изменения управления. Предлагаемый алгоритм обладает высокой вычислительной эффективностью. После обучения вычисление управления сводится к вычислению индексов по результатам измерения, чтению данных из памяти по вычисленным индексам и нахождению максимального значения в векторе небольшой размерности. В работе исследованы условия сходимости алгоритма обучения и ограниченности ошибки управления. Разработанный алгоритм демонстрируется на примере синтеза робастного управления двигателем постоянного тока с независимым возбуждением. В ходе численного моделирования исследуется качество замкнутой системы при изменении параметров и задающего воздействия. Анализ результатов позволяет сделать выводы об эффективности синтезированного алгоритма. В статье приводятся результаты экспериментов, которые демонстрируют техническую реализуемость полученного алгоритма. Данный вопрос является важным, так как анализ источников показывает практически полное отсутствие технической реализации систем управления динамическими объектами, синтезированными с использованием методов обучения с подкреплением.

Ключевые слова: робастное управление, обучение с подкреплением, Q-алгоритм обучения, динамические объекты, неопределенные параметры, сходимость алгоритма обучения.

1. Введение. В настоящее время становятся популярными методы интеллектуального управления, базирующиеся на машинном обучении. Обещающие результаты показывают методы обучения с подкреплением [1], направленные на решение проблемы адаптивного

управления динамическими объектами в условиях неопределенности. Задача синтеза прямого адаптивного управления на базе Q-метода обучения с подкреплением была описана в работе [2]. Здесь можно выделить несколько основных проблем.

Первая проблема заключается в обеспечении асимптотической устойчивости замкнутой системы управления, базирующейся на методах машинного обучения.

Вторая проблема состоит в том, что в процессе обучения имеется возможность выработки обучающимся алгоритмом недопустимых воздействий. В этой связи обучение осуществляется в виртуальной среде, на реальном объекте реализуется дообучение. Чтобы минимизировать риски потери качества и устойчивости управления требуется наличие виртуальной модели, максимально близкой к реальному объекту. Однако, наличие такой модели делает задачу синтеза алгоритма управления реализуемой классическими методами автоматического управления [3]. В этом случае возникает вопрос о преимуществах, которые дает интеллектуальный регулятор.

В работах [4 – 13] проблема сохранения качества и устойчивости системы управления при он-лайн обучении интерпретируется как обеспечение свойства равномерной абсолютной ограниченной устойчивости (Uniformly Ultimate Boundedness Stability – UUB).

При этом можно выделить подход, базирующийся на модели, и безмодельный подход. В работах [4, 6 – 8, 10 – 13] используется подход, основанный на моделях. Рассматриваются дискретные [4, 7] или непрерывные [6, 8, 10 – 13] объекты управления с неопределенными правыми частями и возмущениями. Обычно накладываются условия дифференцируемости [4, 11] или непрерывности в смысле выполнения условий Липшица [6 – 8, 10 – 13] правых частей, внешние возмущения считаются ограниченными, а объект – управляемый. В рассматриваемых работах машинное обучение используется для аппроксимации неопределенных правых частей с их последующей идентификацией, а также для адаптивного решения задачи оптимального управления. В подавляющем числе методов, базирующихся на моделях, для аппроксимации используется однослойная нейронная сеть [4, 6, 8, 10 – 13], в частности популярной является аппроксимация радиальными базисными функциями [4, 11, 12]. Для оценивания оптимального решения уравнения Гамильтона-Якоби-Беллмана и уменьшения ошибки Беллмана также используются однослойные нейронные сети и архитектура обучения с подкреплением, известная как Actor-Critic [1].

Можно выделить ряд ограничений предлагаемых подходов.

Практически во всех статьях, основанных на моделях, за исключением работы [7], используются однослойные нейронные сети. Такие сети способны аппроксимировать нелинейные функции многих переменных, при этом ошибка аппроксимации стремится к нулю, если число нейронов (и, соответственно, число параметров настройки), стремится к бесконечности. Такая аппроксимация не дает принципиальных преимуществ по сравнению с обычной параметризацией и разложением по заданному базису. Она удобна с точки зрения выбора закона настройки параметров на основе теории устойчивости Ляпунова. Однако такой подход не использует преимущества многослойных нейронных сетей, с помощью которых получены наиболее впечатляющие результаты в области искусственного интеллекта.

Также можно отметить, что обеспечение свойства равномерной абсолютной ограниченной устойчивости не гарантирует выполнение прямых показателей качества. На наш взгляд он-лайн адаптация и не может обеспечить выполнение таких требований. Для этого необходимо дополнительно применять офф-лайн методы обучения.

В рамках основанного на моделях подхода различные аспекты проблемы обеспечения безопасности при обучении изучаются в настоящее время [14, 15, 16]. Так в работе [14] обеспечивается построение ограниченной области притяжения методом, сходящим с методом Ляпунова. В работе [15] вводятся ограничения на состояние системы управления, которые выполняются, если известны индикаторная функция, указывающая на выход состояния за заданные ограничения и субоптимальные удовлетворяющие заданным ограничениям действия. В статье [16] выполнение заданных ограничений на состояние системы управления осуществляется в рамках структуры, формирующий параметрическую аппроксимацию решения уравнения Беллмана и формирование ограничений методами обучения с подкреплением.

Проблема обеспечения устойчивости также актуальна в безмодельных подходах [5, 9, 17 – 19], в которых управление строится только на основе анализа входных и выходных данных.

В работах [5] и [9] также обеспечивается свойство UUB. В работах [17, 18] вводятся управляющие барьерные функции (Control Barrier Functions), а также используется предварительное обучение, после которого осуществляется функционирование замкнутой системы. В статье [19] в процессе обучения методом Ляпунова обеспечивается устойчивость. Однако, как в основанных на моделях

подходах не обеспечивается выполнения прямых показателей качества в процессе обучения.

Безмодельные подходы достаточно популярны в различных приложениях. Так в работе [20] рассматривается проблема управления объектом первого порядка с запаздыванием. Для ее решения успешно применяется метод обучения с подкреплением Deep Deterministic Policy Gradient (DDPG). В [21] с применением метода DDPG решена задача перехвата подвижного объекта, который движется по прямойлинейной или круговой траектории.

Проведенный анализ позволяет сделать следующие выводы:

1. Преимущественно исследуются методы он-лайн обучения (адаптации), которые гарантируют устойчивость, но не гарантируют заданного качества управления в процессе обучения.

2. В системах управления динамическими объектами, в подавляющем большинстве статей при анализе устойчивости используются однослойные сети, что удобно для использования теории устойчивости Ляпунова.

3. Проводимый анализ устойчивости не позволяет выбрать структуру нейронной сети, функцию активации и гиперпараметры при обучении, хотя эти характеристики прямо влияют на устойчивость процесса обучения [22].

4. Несмотря на заявленные теоретические гарантии обеспечения устойчивости в статьях отсутствует практическая реализация теоретических результатов. Все исследования остаются в рамках симуляций. Это указывает на недостаточную развитость инженерных методик синтеза систем управления на базе обучения с подкреплением. При этом такая ситуация резко отличается от методов обучения с учителем, на основе которых успешно строятся системы распознавания [23, 24], обработки сигналов [25] и текстов [26], планирования движения [27, 28], реализации регуляторов [29].

В данной работе развивается инженерная методика синтеза регулятора с использованием оф-лайн Q-метода [30]. Преимуществом оф-лайн подхода является то, что он способен обеспечивать заданное качество в течение всего переходного процесса, так как во время функционирования регулятор не обучается. В данной работе рассматривается задача с дискретными значениями управления. Предлагается вариант, позволяющий обеспечить за счет малого интервала дискретизации по уровню и инкрементального способа формирования управления обеспечить слежение за задающим сигналом с малой ошибкой. Кроме того, имеется широкий класс управляемых объектов с релейным характером управления, для

которых такая постановка задачи является актуальной. В частности, релейное управление применяется при управлении мощными двигателями и тепловыми процессами.

Новизна результатов, представленных в настоящей статье, определяется следующими положениями:

1. Предложен инкрементальный способ формирования управляющего воздействия, который обеспечивает робастную стабилизацию управляемого выхода объекта с заданной точностью. Метод требует построения только трех таблиц ценности действий, что определяет его вычислительную эффективность.

2. Предложен способ формирования вознаграждения, предотвращающий резкие изменения управляющих воздействий, что позволяет добиться более плавных переходных процессов в замкнутой системе.

3. Проведенные натурные эксперименты показывают отсутствие необходимости дообучения алгоритма управления при переходе из виртуальной среды к реальному объекту для рассмотренного класса задач. Как правило, такой бесшовный переход считается проблематичным и представляет собой проблемы, известную под названием «разрыв реальности».

2. Постановка задачи. Рассматривается система управления, представленная на рисунке 1, включающая односвязный объект управления (ОУ) и устройство управления (УУ). УУ формирует на вход ОУ управления u_k . С выхода ОУ на вход УУ подаются состояние x_k и вознаграждение R_k . На вход объекта также воздействует возмущение f .




Рис. 1. Структура системы управления

Объектом управления является линейная динамическая стационарная система с неизвестными параметрами и неизмеряемым возмущением, которая описывается системой уравнений вида:

$$\begin{aligned}\frac{dx(t)}{dt} &= Ax(t) + bu(t) + hf(t), \\ y(t) &= c^T x(t),\end{aligned}\tag{1}$$

где $x(t)$ – вектор состояния размерности n ; $u(t)$ – скалярное управляющее воздействие; $f(t)$ – скалярное возмущение; $y(t)$ – регулируемая выходная величина; A – матрица постоянных неизвестных параметров размерностью $n \times n$; b, h – векторы постоянных неизвестных параметров размерностью $n \times 1$; c – вектор известных параметров размерностью $n \times 1$.

Предположение 1. Предполагается, что матрица A является Гурвицевой. Управляющее воздействие принадлежит заданному интервалу $u(t) \in [u_{\min}, u_{\max}]$. Выходная величина объекта (1) ограничена и также принадлежит известному интервалу $y(t) \in [y_{\min}, y_{\max}]$. Внешнее воздействие также ограничено по величине $f_{\min} \leq f(t) \leq f_{\max}$.

Задача состоит в разработке и исследовании интеллектуального робастного алгоритма управления $u = u(x, y_0)$, обеспечивающего стабилизацию выходной величины $y(t)$ в заданной окрестности желаемого значения y_0 . При разработке будем использовать методы обучения с подкреплением на основе временных различий [1].

3. Решение поставленной задачи. Для решения поставленной задачи модель объекта (1) представляется в дискретной форме

$$\begin{aligned}x_{k+1} &= x_k + \Delta t(Ax_k + bu_k + hf_k), \\ y_k &= c^T x_k,\end{aligned}\tag{2}$$

где Δt – шаг дискретизации по времени; k – обозначение дискретного момента времени $t_k = k\Delta t$.

Управление u_k выбирается из множества допустимых управлений

$$u_k \in \{u_i\}, \quad i = 1, 2, \dots, N_u, \quad u_{\min} \leq u_i \leq u_{\max},\tag{3}$$

где N_u – положительное число.

Вознаграждение в момент времени k выбирается в виде квадрата ошибки, взятого с противоположным знаком:

$$R_k = -(y_0 - y_k)^2, \quad (4)$$

где y_k – значение управляемой величины динамического объекта (1) в момент времени t .

В качестве алгоритма обучения используется метод Q-обучения нулевого порядка [1], который относится к методам обучения с разделенной стратегией и описывается выражением:

$$Q_{t+1}(\tilde{x}_k) = Q_t(\tilde{x}_k) + \alpha [R_{k+1} + \gamma \max_u Q_{t+1}(\tilde{x}_{k+1}, u) - Q_t(\tilde{x}_k)], \quad (5)$$

где $Q_{t+1}(\tilde{x}_k)$ – значение ценности состояния $\tilde{x}_k$ в момент времени $t+1$; $Q_t(\tilde{x}_k)$ – значение ценности состояния $\tilde{x}_k$ в момент времени t ; R_{k+1} – вознаграждение за переход в состояние $\tilde{x}_k$; α – шаг обучения; γ – коэффициент обесценивания; $\tilde{x}_k = [x_k \ y_0]^T$.

Выражение (5) формирует обновление ценности действий в каждом состоянии следующим образом.

1) В момент времени t в состоянии $\tilde{x}_k$ выбирается текущее управление u_k в соответствии с выражением

$$u_k = \max_u Q_t(\tilde{x}_k, u). \quad (6)$$

2) Управление u_k (6) подается на вход объекта (1).

3) На следующем шаге $k + 1$ осуществляется вычисление вознаграждения согласно (4) и для нового состояния $\tilde{x}_{k+1}$ определяется оптимальное управление u_{k+1} согласно (6) и его ценность $Q_{t+1}(\tilde{x}_{k+1})$.

4) Согласно выражению (5) осуществляется обновление функции ценности $Q_k(\tilde{x}_k)$.

Таким образом, особенностью выражения (5) является то, что обновление ценности состояния $\tilde{x}_k$, в котором находилась система в момент времени t , осуществляется в момент времени $t+1$, после вычисления максимально полезного действия в состоянии $\tilde{x}_{k+1}$.

Как известно [1], в результате применения описанной процедуры осуществляется максимизация вознаграждения, определяемого выражением

$$G_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots = \sum_{k=0}^{\infty} \gamma^k R_{t+k+1}. \quad (7)$$

Метод Q-обучения, как метод с разделенной с разделенной стратегией, допускает использование ε -жадного алгоритма [1] в процессе обучения и жадного алгоритма в процессе функционирования обученного агента. Основное преимущество метода Q-обучения заключается в том, что обновление функции ценности $Q_k(\tilde{x}_k)$ осуществляется сразу после выполнения действия u_k и определения нового состояния $\tilde{x}_{k+1}$ и вознаграждения R_{t+1} . При этом не требуется хранить массивы состояний и вознаграждений как в методе Монте-Карло, т.е. все операции по обновлению функции ценности (5) являются скалярными. Это позволяет уменьшить требования к вычислительным затратам.

Кроме дискретизации по времени, в процессе обучения Q-методом, используется дискретизация по уровню. Рассмотрим рабочую область объекта (1), в которой переменные состояния $x_i(t)$ ограничены

$$x_{imin} \leq x_i(t) \leq x_{imax}, \quad (8)$$

где x_{imin} , x_{imax} – известные константы; $i=1,2,\dots,n$.

Такие ограничения широко распространены на практике. Например, в электрических системах сигналы ограничены напряжением питания, в электрических двигателях рабочие токи ограничены и при выходе за заданный диапазон осуществляется отключение питания.

Тогда дискретизация диапазона $[x_{imin}, x_{imax}]$ на $n_d + 1$ значение осуществляется в соответствии с выражением

$$x_{ik} = \text{round}(n_d * x_i(k\Delta t) / (x_{imax} - x_{imin})), i = 1, 2, \dots, n, k = 0, 1, 2, \dots \quad (9)$$

Проведем оценку устойчивости системы управления (2) – (6). Для краткости перепишем выражение (5) в виде

$$Q_{k+1} = Q_k + \alpha [R_{k+1} + \gamma \max_u Q_{k+1} - Q_k]. \quad (10)$$

Введем в рассмотрение следующую квадратичную функцию

$$V_k = Q_k^2 + x_k^2. \quad (11)$$

Рассмотрим приращение функции (11)

$$\Delta V_{k+1} = V_{k+1} - V_k = Q_{k+1}^2 + x_{k+1}^2 - Q_k^2 - x_k^2. \quad (12)$$

Подстановка (10) и (2) в правую часть (12) приводит к выражению

$$\Delta V_{k+1} = (Q_k + \alpha [R_{k+1} + \gamma \max_u Q_{k+1} - Q_k])^2 + (x_k + \Delta t(Ax_k + bu_k + hf_k))^2 - Q_k^2 - x_k^2. \quad (13)$$

Согласно Предположению 1 объект управления является устойчивым, а внешние воздействия ограничены. В этой связи вектор x_k также ограничен, поэтому при достаточно малом шаге дискретизации по времени Δt слагаемым $\Delta t(Ax_k + bu_k + hf_k)$ в выражении (13) можно пренебречь. Тогда, при $\Delta t \rightarrow 0$ получаем

$$\Delta V_{k+1} = (Q_k + \alpha [R_{k+1} + \gamma Q_{k+1} - Q_k])^2 - Q_k^2. \quad (14)$$

В выражении (14) раскроем скобки и сократим подобные

$$\Delta V_{k+1} = 2Q_k \alpha [R_{k+1} + \gamma \max_u Q_{k+1} - Q_k] + (\alpha [R_{k+1} + \gamma \max_u Q_{k+1} - Q_k])^2. \quad (15)$$

Выражение $R_{k+1} + \gamma \max_u Q_{k+1} - Q_k$ в (15) хорошо известно, как ошибка Q-метода обучения. Сходимость этой ошибки при $k \rightarrow \infty$ доказана [1, 11]. Поэтому, согласно (15) можно утверждать, что замкнутая система устойчива по Ляпунову, что гарантирует ограниченность всех сигналов.

Описанный алгоритм является стандартным алгоритмом Q-обучения. Он обладает тем недостатком, что при повышении требований к точности стабилизации необходимо увеличивать мощность множества управлений (3). Однако такое увеличение приводит к пропорциональному росту числа Q-таблиц и сложностям при обучении, так как известно, что табличные методы хорошо работают при небольшом числе N_u [1].

В этой связи в данной работе предлагается инкрементальный способ вычисления управления, в котором вычисляется не абсолютное значение управления, а его приращение в соответствии с выражением:

$$u_k = u_{k-1} + \Delta u_k. \quad \Delta u_k = \max_u Q_t(\tilde{x}_k, u), \quad u \in \{-\Delta u, 0, \Delta u\}, \quad (16)$$

где Δu – приращение управления на текущем шаге.

При этом, в выражении (16) $\tilde{x}_k = [x_k \ y_0 \ u_{k-1}]^T$, т.е. состояние системы включает переменные состояния объекта, задающее воздействие и предыдущее значение управления.

Из выражения (16) следует, что регулятор $u_k = u_{k-1} + \max_u Q_t(\tilde{x}_k, u)$ является динамическим, так как значения управления u_k зависят не только от текущего состояния $\tilde{x}_k$, но и от предыдущего значения управляющего воздействия u_{k-1} .

Очевидно, что управление (16) не меняет условия сходимости по сравнению с управлением (6). При этом, выражение (16) обеспечивает более плавное изменение управляющего воздействия.

В системах обучения с подкреплением изменение управляющего воздействия обуславливается не только множеством допустимых управлений, но и вознаграждением. В этой связи в данной работе предлагается модифицированный способ формирования вознаграждения, при котором в выражение (4) добавляется штраф для резких изменений управления:

$$R_k = -(y_0 - y_k)^2 - \beta * |\Delta u|, \quad (17)$$

где β – коэффициент штрафа; $\Delta u = u_k - u_{k-1}$.

На практике всегда присутствуют измерительные шумы, поэтому их необходимо фильтровать. Данный вопрос не является предметом настоящей статьи, поэтому в ней применяется простейший алгоритм сглаживания вида

$$u = \lambda * u_k + (1 - \lambda) * u_{k-1}, \quad (18)$$

где λ – коэффициент сглаживания.

При $\lambda = 0.5$ алгоритм (8) является алгоритмом скользящего усреднения по двум изменениям.

3. Результаты численного моделирования. На рисунках 2 – 4 представлены результаты моделирования замкнутой системы управления (2) – (6), обученной на 3 000 000 эпизодах для следующих параметров: время моделирования эпизода 8.0 с; шаг моделирования 0.01; шаг обучения $\alpha = 0.05$; коэффициент обесценивания $\gamma = 1.0$.

В качестве объекта управления выбран двигатель постоянного тока, модель которого в дискретной форме имеет вид

$$\begin{aligned}\omega_{k+1} &= \omega_k + \frac{\Delta t}{J} (k_m I_k - M_{lk}), \\ I_{k+1} &= I_k + \frac{\Delta t}{L} (u_k - k_m \omega_k - r I_k),\end{aligned}\tag{19}$$

где ω_k , I_k , u_k , M_{lk} – частота вращения, ток статора, управляющее напряжение и момент нагрузки двигателя.




Рис. 2. Изменение частоты вращения в замкнутой системе управления (3) – (6), (19), (20)




Рис. 3. Изменение тока в замкнутой системе (3) – (6), (19), (20)




Рис. 4. Изменение управляющего воздействия в замкнутой системе (3) – (6), (19), (20)

Параметры двигателя (19) являются интервальными и заданы в следующих диапазонах: $J \in [0.1, 0.3]$; $k_m \in [0.7, 1.3]$; $M_l \in [0.1, 0.3]$; $L \in [0.07, 0.13]$; $r \in [0.7, 1.3]$.

Множество управляющих воздействий содержит 5 значений

$$u_k \in \{0, 0.25u_{max}, 0.5u_{max}, 0.75u_{max}, u_{max}\}. \quad (20)$$

При моделировании замкнутой системы значения параметров равны $J = 0.219$, $k_m = 0.944$, $M_l = 0.237$, $L = 0.113$, $r = 1.061$, $\omega_0 = 0.234$.

Полученное значение СКО равно 0.065. При этом СКО рассчитывается по всему переходному процессу. Для установившегося режима СКО равно 0.015, что составляет примерно 45 % от размера ячейки дискретизации пространства состояния.

По сравнению с работой [30], в которой реализовано управление с обратной связью по выходной величине ω_k можно отметить следующее. В работе [30] реализован алгоритм, при котором необходимо обучение при неизвестных, но постоянных параметрах двигателя и заданной нагрузке. При изменении параметров и нагрузки требуется заново обучать алгоритм управления. В данном случае не требуется каждый раз обучать алгоритм управления. Для примера, на рисунках 5–8 представлены переходные процессы в замкнутой системе при скачкообразном изменении нагрузки и желаемой частоты двигателя.




Рис. 5. Изменение частоты в системе (3) – (6), (19), (20) при скачке задающего воздействия ω_0






Рис. 6. Изменение управления в системе (3) – (6), (19), (20) при скачке задающего воздействия ω_0

На рисунке 5 и рисунке 6 в момент времени $t = 4$ с происходит скачкообразное изменение задающей частоты вращения вала двигателя с 0.8 до 0.5. Алгоритм управления (6) после переходного процесса стабилизирует частоту вращения в окрестности нового значения. При моделировании замкнутой системы ее параметры сгенерированы случайным образом и равны: $J = 0.119$, $k_m = 0.969$, $M_l = 0.115$, $L = 0.106$, $r = 0.922$. СКО ошибки управления в течение всего времени составило 0.034, а в установившемся режиме 0.017.


 Рис. 7. Изменение частоты в системе (3) – (6), (19), (20) при скачке нагрузки M_l

 Рис. 8. Изменение управления в системе (3) – (6), (19), (20) при скачке нагрузки M_l

На рисунке 9 представлена проекция функции ценности для действия $u_k = 0$ при $\omega_0 = 0.1$. Функция построена в логарифмическом масштабе. Так как значения функции отрицательные, то построена функция логарифма от модуля функции ценности. Поэтому ее оптимальное значение находится в минимуме, который при малых токах примерно соответствует значению $\omega = \omega_0$. При увеличении тока оптимальное значение функции ценности смещается в сторону возрастания ω .




Рис. 9. Проекция функции ценности $\log(-Q(\omega, I))$ при $u_k = 0$ и $\omega_0 = 0.1$

На рисунках 10 и 11 представлены результаты моделирования обученной замкнутой системы для управления частотой вращения двигателя для инкрементального управления (16).




Рис. 10. Изменение частоты в замкнутой системе (16), (4), (5), (19)

Моделирование проводилось при следующих параметрах двигателя: $J = 0.29$, $k_m = 1.081$, $M_l = 0.15$, $L = 0.081$, $r = 0.975$, $\omega_0 = 0.7$. В момент времени $t=4$ с имеется скачок нагрузки до значения $M_l = 0.2$. При этом величина $\Delta u = 0.1$, шаг обновления управления равен 0.05 с, а шаг моделирования двигателя 0.01 .

СКО замкнутой системы в установившемся режиме составило 0.017, что примерно в 2 раза меньше размера ячейки дискретизации. Отметим, что моделируется гибридная система, в которой управляющий алгоритм является дискретным, а объект непрерывным.




Рис. 11. Изменение управления в замкнутой системе (16), (4), (5), (19)

4. Результаты натуральных экспериментов. Для тестирования метода управления приводом на основе Q-обучения был выбран малый привод постоянного тока RB300200-0B101RE его характеристики были измерены эмпирически и приведены в таблице 1.

Таблица 1. Параметры привода постоянного тока

Параметры привода	Величина	Погрешность
Момент инерции, (кг * м ²)	10 ⁻⁶	5·10 ⁻⁷
Коэффициент вязкого трения, (Н*м*с/рад)	2·10 ⁻⁶	5·10 ⁻⁷
Противо-ЭДС, (В*с/рад)	0.0169	0.002
Сопротивление, (Ом)	10	1.5
Индуктивность, (Гн)	2.83·10 ⁻³	3·10 ⁻⁴
Максимальное напряжение, (В)	12	—
Максимальная угловая скорость, (рад/с)	710	—

В ходе экспериментов исследованы формирование управления на основе множества (3). Для обучения и формирования управления использованы средства Matlab/Simulink.

При управлении на основе множества (3) обучение длилось 500 тыс. эпизодов по 5 секунд каждый. После обучения в виртуальной среде алгоритм управления применяется на реальном приводе. Шаг дискретизации управляющего напряжения равен 0.5 В. Состояния по угловой скорости дискретизируются с шагом 10 рад/с.

Схема системы управления в Matlab/Simulink представлена на рисунке 12.




Рис. 12. Схема системы управления в Matlab/Simulink

Схема подключения привода представлена на рисунке 13, а внешний вид стенда для эксперимента – на рисунке 14.




Рис. 13. Блок-схема подключения привода

Как видно из рисунка 13, подключение привода осуществляется через микроконтроллер STM32F767 и преобразователь L298N. Для измерения частоты вращения вала двигателя используется датчик ЛИР-ДА23Т.




Рис. 14. Схема управления реальным приводом

Переходные процессы обученной системы управления представлены на рисунках 15 и 16.

Результаты эксперимента показывают, что ошибка поддержания частоты составляет около 25 рад/с, что составляет 2,5 шага дискретизации по частоте. Основной вклад в ошибку управления вносят измерительные шумы.

Результаты моделирования для системы управления с вознаграждением (17) и фильтром (18) представлены на рисунках 17 и 18. Как видно из рисунка 17 ошибка управления составила около 10 рад/с, что соответствует используемому шагу дискретизации частоты вращения по уровню.




Рис. 15. Угловая скорость для управления из множества (3)




Рис. 16. Угловая скорость для управления из множества (3)




Рис. 17. Угловая скорость для управления из множества (3), вознаграждения (19) и фильтра (20)




Рис. 18. Угловая скорость для управления из множества (3), вознаграждения (19) и фильтра (20)

Заключение. В статье представлены результаты исследования по применению Q-метода обучения с подкреплением для стабилизации выходной величины динамического объекта в заданном значении. Проведенный анализ литературы показал, что в большинстве работ развиваются он-лайн методы обучения, которые не позволяют удовлетворить требуемым прямым показателям качества в процессе адаптации. В этой связи офф-лайн методы обучения представляют интерес для технических систем.

Результаты, полученные в данной статье, позволяют сделать следующие выводы:

- офф-лайн Q-метод обучения с дискретным входом и выходом позволяет стабилизировать выход динамической системы с возмущением, параметры которой являются интервальными. При этом стабилизация осуществляется с точностью, определяемой шагом дискретизации;

- с использованием натурального эксперимента показано отсутствие необходимости дообучения алгоритма управления при переходе из виртуальной среды к реальному объекту. Этот факт позволяет создавать на основе алгоритмов обучения с подкреплением новый класс робастных систем управления для исполнительных механизмов;

- полученный алгоритм является вычислительно эффективным. Для нахождения управления достаточно реализовать доступ к элементам табличных функций ценности по имеющимся индексам и функцию поиска максимума в массиве размером $1 \times N_u$. По сравнению с традиционными ПИД-регуляторами, требующими реализации численного интегрирования и дифференцирования, такой регулятор обладает более высоким быстродействием;

- в работе предложен подход к уменьшению числа N_u , который заключается в инкрементальной форме вычисления управления (18). В этом случае управление u_k становится динамическим, так как оно зависит от предыдущего значения u_{k-1} . Изменяя величину Δu_k можно уменьшать величину дискретизации управления при $N_u = 3$.

Представленный в данной статье подход может быть эффективно применен для построения робастных систем управления объектами 2-3-го порядков. Очевидно, увеличение числа переменных приведет к необходимости использования различных, в том числе нейросетевых, аппроксимаций. Однако, использование аппроксимации функции ценности, вместе с разделенной стратегией обучения, при необходимости использования оценок вознаграждений вместо

фактических вознаграждений или полных доходов, приводит к проблеме расходимости алгоритмов обучения. Кроме того, сходимость процесса аппроксимации, строго говоря, доказана только для однослойных нейронных сетей (которыми может быть представлено, например, радиально-базисное или полиномиальное разложение). Наиболее точная многомерная аппроксимация достигается многослойными нейронными сетями, для которых не доказана асимптотическая сходимость в динамических системах.

Литература

1. Sutton R., Barto A. Reinforcement Learning. An Introduction. Second Edition. Cambridge: MIT Press, 2018. vol. 1. no. 1. pp. 9–11.
2. Sutton R.S., Barto A.G., Williams R.J. Reinforcement learning is direct adaptive optimal control. IEEE Control Systems Magazine. 2002. vol. 12(2). pp. 19–22.
3. Pshikhov V., Medvedev M. Multi-Loop Adaptive Control of Mobile Objects in Solving Trajectory Tracking Tasks. Automation and Remote Control. 2020. vol. 81. pp. 2078–2093. DOI: 10.1134/S0005117920110090.
4. Shih P., Kaul B., Jagannathan S., Drallmeier J. Near Optimal Output-Feedback Control of Nonlinear Discrete-Time Systems in Nonstrict Feedback Form with Application to Engines. IEEE International Joint Conference on Neural Networks. 2007. pp. 396–401.
5. Xu B., Yang C., Shi Z. Reinforcement Learning Output Feedback NN Control Using Deterministic Learning Technique. IEEE Transactions on Neural Networks and Learning Systems. 2014. vol. 25(3). pp. 635–641. DOI: 10.1109/TNNLS.2013.2292704.
6. Mu C., Ni Z., Sun C., He H. Data-Driven Tracking Control with Adaptive Dynamic Programming for a Class of Continuous-Time Nonlinear Systems. IEEE Transactions on Cybernetics. 2016. vol. 47(6). pp. 1460–1470.
7. Wang A., Liao X., Dong T. Event-Driven Optimal Control for Uncertain Nonlinear Systems with External Disturbance via Adaptive Dynamic Programming. Neurocomputing. 2018. vol. 281. pp. 188–195.
8. Kim J.W., Oh T.H., Son S.H., Jeong D.H., Lee J.M. Convergence Analysis of the Deep Neural Networks Based Globalized Dual Heuristic Programming. Automatica. 2020. vol. 122.
9. Luo B., Yang Y., Liu D., Wu H.-N. Event-Triggered Optimal Control with Performance Guarantees Using Adaptive Dynamic Programming. IEEE Transactions on Neural Networks and Learning Systems. 2019. vol. 31(1). pp. 76–88.
10. Yang X., Xu M., Wei Q. Dynamic Event-Sampled Control of Interconnected Nonlinear Systems Using Reinforcement Learning. IEEE Transactions on Neural Networks and Learning Systems. 2022. vol. 35(1). pp. 923–937. DOI: 10.1109/TNNLS.2022.3178017.
11. Zhang H., Zhao X., Wang H., Zong G., Xu N. Hierarchical Sliding-Mode Surface-Based Adaptive Actor-Critic Optimal Control for Switched Nonlinear Systems With Unknown Perturbation. IEEE Transactions on Neural Networks and Learning Systems. 2022. vol. 35(2). pp. 1559–1571. DOI: 10.1109/TNNLS.2022.3183991.
12. Dong C., Chen L., Dai S.-L. Performance-Guaranteed Adaptive Optimized Control of Intelligent Surface Vehicle Using Reinforcement Learning. IEEE Transactions on Intelligent Vehicles. 2023. vol. 9. no. 2. pp. 3581–3592. DOI: 10.1109/TIV.2023.3338486.

13. Dao P.N., Phung M.H. Nonlinear Robust Integral Based Actor-Critic Reinforcement Learning Control for a Perturbed Three-Wheeled Mobile Robot with Mecanum Wheels. *Computers and Electrical Engineering*. 2025. vol. 121. DOI: 10.1016/j.compeleceng.2024.109870.
14. Berkenkamp F., Turchetta M., Schoellig A., Krause A. Safe Model-Based Reinforcement Learning with Stability Guarantees. *Advances in Neural Information Processing Systems*. 2017. vol. 30. pp. 908–918.
15. Thananjeyan B., Balakrishna A., Rosolia U., Li F., McAllister R., Gonzalez J.E., Levine S., Borrelli F., Goldberg K. Safety Augmented Value Estimation From Demonstrations (SAVED): Safe Deep Model-Based RL for Sparse Cost Robotic Tasks. *IEEE Robotics and Automation Letters*. 2020. vol. 5(2). pp. 3612–3619.
16. Zanon M., Gros S. Safe Reinforcement Learning Using Robust MPC. *IEEE Transactions on Automatic Control*. 2020. vol. 66(8). pp. 3638–3652. DOI: 10.1109/TAC.2020.3024161.
17. Cheng R., Orosz G., Murray R.M., Burdick J.W. End-to End Safe Reinforcement Learning through Barrier Functions for Safety Critical Continuous Control Tasks. *Proceedings of the AAAI Conference on Artificial Intelligence (AAAI-19)*. 2019. vol. 33. no. 01. pp. 3387–3395.
18. Choi J., Castaneda F., Tomlin C.J., Sreenath K. Reinforcement Learning for Safety-Critical Control Under Model Uncertainty, Using Control Lyapunov Functions and Control Barrier Functions. *Conference Robotics: Science and Systems*. 2020.
19. Han M., Zhang L., Wang J., Pan W. Actor-Critic Reinforcement Learning for Control With Stability Guarantee. *IEEE Robotics and Automation Letters*. 2020. vol. 5(4). pp. 6217–6224.
20. Боровик В.С., Шидловский С.В. Обучение с подкреплением в системах управления объектами с транспортным запаздыванием. *Автометрия*. 2021. Т. 57(3). С. 48–57.
21. Галиев А.А., Медведев А.И., Насонов И.А. Нейросетевой алгоритм перехвата машиной Дубинса целей, движущихся по известным траекториям. *Автоматика и телемеханика*. 2023. № 3. С. 3–21.
22. Хапкин Д.Л., Феофилов С.В. Синтез устойчивых нейросетевых регуляторов для объектов с ограничителями в условиях неполной информации. *Мехатроника, автоматизация, управление*. 2024. Т. 25(7). С. 345–353. DOI: 10.17587/mau.25.345-353.
23. Фаворская М.Н., Пахирка А.И. Восстановление аэрофотоснимков сверхвысокого разрешения с учетом семантических особенностей. *Информатика и автоматизация*. 2024. Т. 23(4). С. 1047–1076. DOI: 10.15622/ia.23.4.5.
24. Чен Х., Игнатъева С.А., Богуш Р.П., Абламейко С.В. Повторная идентификация людей в системах видеонаблюдения с использованием глубокого обучения: анализ существующих методов. *Автоматика и телемеханика*. 2023. № 5. С. 61–112. DOI: 10.31857/S0005231023050057.
25. Понимаш З.А., Потанин М.В. Метод и алгоритм извлечения признаков из цифровых сигналов на базе нейросетей трансформер. *Известия ЮФУ. Технические науки*. 2024. № 6. С. 52–64. DOI: 10.18522/2311-3103-2024-6-52-64.
26. Голубинский А.Н., Толстых А.А., Толстых М.Ю. Автоматическая генерация аннотаций научных статей на основе больших языковых моделей. *Информатика и автоматизация*. 2025. Т. 24(1). С. 275–301. DOI: 10.15622/ia.24.1.10.
27. Hamdan N., Medvedev M., Pshikhopov V. Method of Motion Path Planning Based on a Deep Neural Network with Vector Input. *Mekhatronika, Avtomatizatsiya, Upravlenie*. 2024. vol. 25(11). pp. 559–567. DOI: 10.17587/mau.25.559-567.
28. Gaiduk A.R., Martjanov O.V., Medvedev M.Yu., Pshikhopov V.Kh., Hamdan N., Farhood A. Neural network based control system for robots group operating in 2-d

- uncertain environment. Mekhatronika, Avtomatizatsiya, Upravlenie. 2020. vol. 21(8). pp. 470–479. DOI: 10.17587/mau.21.470-479.
29. Жилов Р.А. Постройка ПИД-регулятора с использованием нейронных сетей // Известия Кабардино-Балкарского научного центра РАН. 2022. № 5(109). С. 38–47. DOI: 10.35330/1991-6639-2022-5-109-38-47.
 30. Карапеев А.Н., Косенко Е.Ю., Медведев М.Ю., Пшихопов В.Х. Исследование интеллектуального адаптивного алгоритма управления на базе метода обучения с подкреплением. Известия ЮФУ. Технические науки. 2025. № 2. С. 162–175.

Медведев Михаил Юрьевич — д-р техн. наук, доцент, ведущий научный сотрудник, НИИ робототехники и процессов управления, Южный федеральный университет (ЮФУ). Область научных интересов: адаптивное и робастное управление мобильными роботами, оценивание возмущений, методы анализа и синтеза систем автоматического управления. Число научных публикаций — 260. medvmihal@sfnedu.ru; улица Шевченко, 2, 347922, Таганрог, Россия; р.т.: +7(863)437-1694.

Пшихопов Вячеслав Хасанович — д-р техн. наук, профессор, директор, НИИ робототехники и процессов управления, Южный федеральный университет (ЮФУ). Область научных интересов: управление мобильными роботами в неопределенных средах, оптимальное управление роботами, анализ и синтез систем группового управления, интеллектуальное управление и планирование в робототехнике. Число научных публикаций — 300. pshichop@rambler.ru; улица Шевченко, 2, 347922, Таганрог, Россия; р.т.: +7(863)437-1694.

Евдокимов Игорь Дмитриевич — аспирант, инженер, НИИ робототехники и процессов управления, Южный федеральный университет (ЮФУ). Область научных интересов: адаптивное и робастное управление мобильными роботами. Число научных публикаций — 1. ievdokimov@sfnedu.ru; улица Шевченко, 2, 347922, Таганрог, Россия; р.т.: +7(863)437-1694.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда № 25-61-00017, «Интеллектуальные методы траекторного управления робототехническими комплексами в условиях параметрических и внешних возмущений», <https://rscf.ru/project/25-61-00017/> на базе ФГАОУ ВО «Южный федеральный университет».

M. MEDVEDEV, V. PSHIKHOPOV, I. EVDOKIMOV
**A ROBUST CONTROL ALGORITHM FOR SINGLE INPUT
SINGLE OUTPUT DYNAMIC OBJECT BASED ON TABLE-BASED
Q-METHOD OF REINFORCEMENT LEARNING**

Medvedev M., Pshikhopov V., Evdokimov I. A Robust Control Algorithm for Single Input Single Output Dynamic Object Based on Table-Based Q-Method of Reinforcement Learning.

Abstract. The article provides an overview in the field of dynamic object control systems based on reinforcement learning. Based on the analysis, it is concluded that the development of control methods based on reinforcement learning is relevant. The article proposes an intelligent algorithm for robust control of stable dynamic objects with one input and one output, based on the tabular Q-learning method of zero order. The algorithm stabilizes the output value of the control object with a given error if the parameters and external disturbances of the object are piecewise constant unknown quantities, and the state vector is measurable. The novelty of the proposed algorithm lies in a new incremental method of control formation, which allows, based on a set of three possible actions, to stabilize the control object. The proposed method of forming a set of control actions makes it possible to ensure the required accuracy of stabilizing the output of an object by changing the amplitude of the control increment. The proposed algorithm has high computational efficiency. After training, the control calculation is reduced to calculating indexes based on measurement results, reading data from memory based on calculated indexes, and finding the maximum value in a small vector. For a discrete description of the control object, the conditions of convergence of the learning algorithm and the limitation of the control error are investigated. The developed algorithm is demonstrated by the example of the synthesis of robust control of a DC motor with independent excitation. In the course of numerical simulation, the quality of a closed system is investigated when the parameters and the control action change. The analysis of the simulation results allows us to draw conclusions about the effectiveness of the synthesized algorithm. The article also provides the results of a real experiment that demonstrate the technical feasibility of the algorithm obtained. This issue is important, since the analysis of sources shows an almost complete lack of technical implementation of control systems for dynamic objects synthesized using reinforcement learning methods.

Keywords: robust control, reinforcement learning, Q-learning algorithm, dynamic objects, uncertain parameters, convergence of the learning algorithm.

References

1. Sutton R., Barto A. Reinforcement Learning. An Introduction. Second Edition. Cambridge: MIT Press, 2018. vol. 1. no. 1. pp. 9–11.
2. Sutton R.S., Barto A.G., Williams R.J. Reinforcement learning is direct adaptive optimal control. IEEE Control Systems Magazine. 2002. vol. 12(2). pp. 19–22.
3. Pshikhopov V., Medvedev M. Multi-Loop Adaptive Control of Mobile Objects in Solving Trajectory Tracking Tasks. Automation and Remote Control. 2020. vol. 81. pp. 2078–2093. DOI: 10.1134/S0005117920110090.
4. Shih P., Kaul B., Jagannathan S., Drallmeier J. Near Optimal Output-Feedback Control of Nonlinear Discrete-Time Systems in Nonstrict Feedback Form with Application to Engines. IEEE International Joint Conference on Neural Networks. 2007. pp. 396–401.

5. Xu B., Yang C., Shi Z. Reinforcement Learning Output Feedback NN Control Using Deterministic Learning Technique. *IEEE Transactions on Neural Networks and Learning Systems*. 2014. vol. 25(3). pp. 635–641. DOI: 10.1109/TNNLS.2013.2292704.
6. Mu C., Ni Z., Sun C., He H. Data-Driven Tracking Control with Adaptive Dynamic Programming for a Class of Continuous-Time Nonlinear Systems. *IEEE Transactions on Cybernetics*. 2016. vol. 47(6). pp. 1460–1470.
7. Wang A., Liao X., Dong T. Event-Driven Optimal Control for Uncertain Nonlinear Systems with External Disturbance via Adaptive Dynamic Programming. *Neurocomputing*. 2018. vol. 281. pp. 188–195.
8. Kim J.W., Oh T.H., Son S.H., Jeong D.H., Lee J.M. Convergence Analysis of the Deep Neural Networks Based Globalized Dual Heuristic Programming. *Automatica*. 2020. vol. 122.
9. Luo B., Yang Y., Liu D., Wu H.-N. Event-Triggered Optimal Control with Performance Guarantees Using Adaptive Dynamic Programming. *IEEE Transactions on Neural Networks and Learning Systems*. 2019. vol. 31(1). pp. 76–88.
10. Yang X., Xu M., Wei Q. Dynamic Event-Sampled Control of Interconnected Nonlinear Systems Using Reinforcement Learning. *IEEE Transactions on Neural Networks and Learning Systems*. 2022. vol. 35(1). pp. 923–937. DOI: 10.1109/TNNLS.2022.3178017.
11. Zhang H., Zhao X., Wang H., Zong G., Xu N. Hierarchical Sliding-Mode Surface-Based Adaptive Actor-Critic Optimal Control for Switched Nonlinear Systems with Unknown Perturbation. *IEEE Transactions on Neural Networks and Learning Systems*. 2022. vol. 35(2). pp. 1559–1571. DOI: 10.1109/TNNLS.2022.3183991.
12. Dong C., Chen L., Dai S.-L. Performance-Guaranteed Adaptive Optimized Control of Intelligent Surface Vehicle Using Reinforcement Learning. *IEEE Transactions on Intelligent Vehicles*. 2023. vol. 9. no. 2. pp. 3581–3592. DOI: 10.1109/TIV.2023.3338486.
13. Dao P.N., Phung M.H. Nonlinear Robust Integral Based Actor-Critic Reinforcement Learning Control for a Perturbed Three-Wheeled Mobile Robot with Mecanum Wheels. *Computers and Electrical Engineering*. 2025. vol. 121. DOI: 10.1016/j.compeleceng.2024.109870.
14. Berkenkamp F., Turchetta M., Schoellig A., Krause A. Safe Model-Based Reinforcement Learning with Stability Guarantees. *Advances in Neural Information Processing Systems*. 2017. vol. 30. pp. 908–918.
15. Thananjeyan B., Balakrishna A., Rosolia U., Li F., McAllister R., Gonzalez J.E., Levine S., Borrelli F., Goldberg K. Safety Augmented Value Estimation From Demonstrations (SAVED): Safe Deep Model-Based RL for Sparse Cost Robotic Tasks. *IEEE Robotics and Automation Letters*. 2020. vol. 5(2). pp. 3612–3619.
16. Zanon M., Gros S. Safe Reinforcement Learning Using Robust MPC. *IEEE Transactions on Automatic Control*. 2020. vol. 66(8). pp. 3638–3652. DOI: 10.1109/TAC.2020.3024161.
17. Cheng R., Orosz G., Murray R.M., Burdick J.W. End-to-End Safe Reinforcement Learning through Barrier Functions for Safety Critical Continuous Control Tasks. *Proceedings of the AAAI Conference on Artificial Intelligence (AAAI-19)*. 2019. vol. 33. no. 01. pp. 3387–3395.
18. Choi J., Castaneda F., Tomlin C.J., Sreenath K. Reinforcement Learning for Safety-Critical Control Under Model Uncertainty, Using Control Lyapunov Functions and Control Barrier Functions. *Conference Robotics: Science and Systems*. 2020.
19. Han M., Zhang L., Wang J., Pan W. Actor-Critic Reinforcement Learning for Control With Stability Guarantee. *IEEE Robotics and Automation Letters*. 2020. vol. 5(4). pp. 6217–6224.

20. Borovik V.S., Shidlovskii S.V. [Reinforcement Learning in Plant Control Systems with Transport Lag]. Optoelectronics. Instrumentation and Data Processing. 2021. vol. 57. pp. 265–272.
21. Galyaev A.A., Medvedev A.I., Nasonov I.A. [Neural network algorithm for intercepting targets moving along known trajectories by a Dubins' car]. Avtomat. i Telemekh. – Automation and telemechanics. 2023. no. 3. pp. 3–21. (In Russ.).
22. Khapkin D.L., Feofilov S.V. [The Method of Synthesis of a Stable Closed-Loop Object Control System with Limiters]. Mekhatronika, Avtomatizatsiya, Upravlenie – Mechatronics, automation, control. 2024. vol. 25(7). pp. 345–353. DOI: 10.17587/mau.25.345-353. (In Russ.).
23. Favorskaya M., Pakhirka A. [Restoration of semantic-based super-resolution aerial images]. Informatics and Automation. 2024. vol. 23(4). pp. 1047–1076. DOI: 10.15622/ia.23.4.5. (In Russ.).
24. Chen K., Ignat'eva S.A., Bogush R.P., Ablameyko S.V. [Re-identification of people in video surveillance systems using deep learning: an analysis of existing methods]. Avtomat. i Telemekh. – Automation and telemechanics. 2023. no. 5. pp. 61–112. DOI: 10.31857/S0005231023050057. (In Russ.).
25. Ponimash Z.A., Potanin M.V. [Method and algorithm for extracting features from digital signals based on neural networks transformer]. Izvestiya JuFU. Tehnicheskie nauki – Izvestiya SFEDU. Technical sciences. 2024. no. 6. pp. 52–64. DOI: 10.18522/2311-3103-2024-6-52-64. (In Russ.).
26. Golubinskiy A., Tolstykh A., Tolstykh M. [Automatic Generation of Scientific Articles Abstracts Based on Large Language Models]. Informatics and Automation. 2025. vol. 24(1). pp. 275–301. DOI: 10.15622/ia.24.1.10. (In Russ.).
27. Hamdan N., Medvedev M., Pshikhopov V. Method of Motion Path Planning Based on a Deep Neural Network with Vector Input. Mekhatronika, Avtomatizatsiya, Upravlenie. 2024. vol. 25(11). pp. 559–567. DOI: 10.17587/mau.25.559-567.
28. Gaiduk A.R., Martjanov O.V., Medvedev M.Yu., Pshikhopov V.Kh., Hamdan N., Farhood A. Neural network based control system for robots group operating in 2-d uncertain environment. Mekhatronika, Avtomatizatsiya, Upravlenie. 2020. vol. 21(8). pp. 470–479. DOI: 10.17587/mau.21.470-479.
29. Zhilov R.A. [Building a PID controller using neural networks]. Izvestiya Kabardino-Balkarskogo nauchnogo centra RAN – News of the Kabardino-Balkarian Scientific Center of RAS. 2022. no. 5(109). pp. 38–47. DOI: 10.35330/1991-6639-2022-5-109-38-47. (In Russ.).
30. Karapeev A.N., Kosenko E.Y., Medvedev M.Yu., Pshikhopov V.Kh. [Research of an intelligent adaptive control algorithm based on the reinforcement learning method]. Izvestiya JuFU. Tehnicheskie nauki – Izvestiya SFEDU. Engineering Sciences. 2025. no. 2. pp. 162–175. (In Russ.).

Medvedev Mikhail — Ph.D., Dr.Sci., Associate Professor, Leading researcher, R&D Institute of robotics and control systems, Southern Federal University (SFedU). Research interests: planning and control of autonomous robots with a focus on adaptive and robust control, path planning methods, and neural network planning. The number of publications — 260. medvmihal@sfedu.ru; 2, Shevchenko St., 347922, Taganrog, Russia; office phone: +7(863)437-1694.

Pshikhopov Viacheslav — Ph.D., Dr.Sci., Professor, Director, R&D Institute of robotics and control systems, Southern Federal University (SFedU). Research interests: planning and control of autonomous robots and manipulators with a focus on time-optimal control, control in obstructed unmapped environments, and intelligent and group control. The number of

publications — 300. pshichop@rambler.ru; 2, Shevchenko St., 347922, Taganrog, Russia; office phone: +7(863)437-1694.

Evdokimov Igor — Post-graduate student, engineer, R&D Institute of robotics and control systems, Southern Federal University (SFedU). Research interests: planning and control of autonomous robots with a focus on adaptive and robust control. The number of publications — 1. ievdokimov@sfedu.ru; 2, Shevchenko St., 347922, Taganrog, Russia; office phone: +7(863)437-1694.

Acknowledgements. The research was funded by the Russian Science Foundation project No.25-61-00017, «Intelligent methods of trajectory control of robotic complexes under conditions of parametric and external perturbations», <https://rscf.ru/project/25-61-00017/> implemented by the Southern Federal University.

А.С. Антипов, Ю.Г. Кокунько, Д.А. Вольф, А.С. Широков
**СИНТЕЗ КОМБИНИРОВАННОГО УПРАВЛЕНИЯ
ОРИЕНТАЦИЕЙ И ВЫСОТОЙ КВАДРОКОПТЕРА НА ОСНОВЕ
БЛОЧНОГО ПОДХОДА С СИГМОВИДНЫМИ ОБРАТНЫМИ
СВЯЗЯМИ**

Антипов А.С., Кокунько Ю.Г., Вольф Д.А., Широков А.С. Синтез комбинированного управления ориентацией и высотой квадрокоптера на основе блочного подхода с сигмовидными обратными связями.

Аннотация. В работе рассматривается проблема управления ориентацией и высотой квадрокоптера при наличии неопределенностей в модели объекта. При решении данной проблемы особенно актуально учитывать особенности объекта: сильную подверженность колебаниям крена, тангажа и высоты из-за конструкции квадрокоптера и динамики моторов (при этом рыскание наименее подвержено колебаниям из-за динамики моторов по сравнению с другими регулируемыми переменными). Для достижения высокого качества регулирования при наличии неопределенностей, как правило, применяют комбинированное управление. Оно строится как сумма двух частей: базовой стабилизирующей и части, компенсирующей неопределенности с помощью наблюдателя возмущений. Стандартно обе части содержат линейные обратные связи. Однако при обработке выходными переменными объекта негладких задающих воздействий линейные обратные связи могут приводить к перерегулированию и к увеличению колебательности. Для предотвращения этих проблем в работе предложен закон комбинированного управления с гладкими и ограниченными обратными связями в виде гиперболического тангенса. Данные обратные связи используются и в регуляторе, и в наблюдателе возмущений. При этом синтез управлений осуществляется на основе структурных свойств объекта с помощью блочного подхода. Его применение обеспечило инвариантность выходных переменных по отношению не только к согласованным, но и к несогласованным неопределенностям, а также позволило построить наблюдатель возмущений минимально возможного порядка. Кроме того, дополнительно для уменьшения колебаний в закон управления введена часть с ускорениями объекта. Для реализации предложенного подхода достаточно знать номинальные значения некоторых параметров объекта и допустимые границы изменения неопределенностей. Приведены результаты натурных экспериментов на квадрокоптере с рамой F450 и результаты сравнительного анализа предложенного подхода с тем, где используются линейные управления.

Ключевые слова: беспилотный летательный аппарат, внешние возмущения, комбинированное управление, блочный подход, гиперболический тангенс.

1. Введение. В настоящее время применение беспилотных летательных аппаратов (БПЛА), в том числе квадрокоптеров, активно развивается во многих сферах для выполнения разнообразных задач: для картографии и геодезии; для съемки с воздуха; для обеспечения правопорядка и общественной безопасности; для поисковых, спасательных работ и оказания помощи; для лесного и сельского хозяйства; для инспекции линий электропередач; для образовательных и других целей. В связи с этим актуальна разработка автоматических

систем управления квадрокоптерами, позволяющая выполнять все необходимые цели и учитывающая особенности функционирования объекта и его математической модели. Из этих особенностей отметим нелинейность, относительно большой порядок модели, дефицит управлений, наличие перекрестных связей, параметрических неопределенностей и внешних возмущений, неполный комплект датчиков. Из-за комплекса данных особенностей разработка робастной системы слежения для квадрокоптера считается сложной задачей. При этом четыре управления позволяют независимо управлять только четырьмя выходными переменными. Их выбор зависит от функций, которые должен выполнять объект. В процессах автоматического управления квадрокоптером без априорного рабочего сценария, где не может быть задействован оператор БПЛА (например, в поисковых и спасательных работах), целесообразно принять три линейные координаты и угол рыскания в качестве выходных переменных. Для решения задач фото- и видеосъемки могут использоваться углы Эйлера и высота, желаемые значения которых оператор БПЛА задает с помощью пульта управления.

Распространенными методами управления квадрокоптерами являются пропорционально-дифференцирующие (ПД) и пропорционально-интегрально-дифференцирующие (ПИД) регуляторы [1 – 3], методы оптимального [4 – 6], робастного [7 – 9] и адаптивного управления [10 – 13]. ПД и ПИД-регуляторы широко применяются в различных технических системах в силу простой реализации, которую можно осуществить без знания математической модели объекта управления. Однако изменение режимов функционирования объекта и внешних возмущений обычно требует перенастройки коэффициентов регулятора. Чтобы решить эту проблему для настройки коэффициентов применяют механизмы адаптации [14] и нейронные сети [15]. Однако это увеличивает количество вычислений в реальном времени и требует мощных бортовых процессоров, а также приводит к проблеме переобучения нейронных сетей.

Методы оптимального управления обеспечивают максимизацию или минимизацию выбранных критериев. Однако эти методы чувствительны к параметрическим неопределенностям и неизвестным внешним возмущениям, которые всегда имеются на практике. Из-за этого методы становятся квазиоптимальными.

Среди методов робастного управления выделим методы управления на скользящих режимах [8 – 9] и методы компенсации возмущений с помощью построения их наблюдателя [16 – 20]. Стандартные методы управления на скользящих режимах

обеспечивают инвариантность по отношению к согласованным неопределенностям и возмущениям (тем, которые действуют по одним каналам с управлением) за счет их подавления. Существуют также модификации методов при наличии несогласованных возмущений [21]. Недостатком методов управления на скользящих режимах является «чаттеринг» (паразитные колебания в установившемся режиме, которые возникают из-за конечной частоты переключений и инерции исполнительных устройств). Для борьбы с «чаттерингом» исследователи повышают порядок скользящих режимов [22], однако это увеличивает вычислительную сложность и, как правило, не позволяет полностью избавиться от явления «чаттеринга». В настоящее время для улучшения показателей качества регулирования исследователи комбинируют описанные стандартные методы с методами искусственного интеллекта [23] (в том числе с использованием нейросетей) и с методами нечеткой логики [24].

Компенсировать неопределенности и возмущения можно с помощью построения их наблюдателей. При этом переменные наблюдателей предоставляют оценки неопределенностей в режиме реального времени. Таким образом, в отличие от ПИД-регуляторов, применение данного метода может обеспечить работоспособность замкнутой системы при смене режимов работы объекта без изменения коэффициентов регулятора. Для этого достаточно знать допустимые диапазоны изменения неизвестных параметров и возмущений. При этом вычислительная сложность схемы управления с наблюдателем возмущений сопоставима с ПИД-регулированием. Однако настройка схемы с наблюдателем может быть более трудоемкой в силу того, что для ПИД-регулирования разработаны удобные инструменты автоматической настройки в MATLAB с пользовательским интерфейсом (PID Tuner app).

По сравнению с методом компенсации возмущений на основе построения их наблюдателя, для реализации методов адаптивного управления не требуется устойчивости разомкнутой системы, и не нужно знать границы изменения неопределенностей. Коэффициенты регулятора в режиме реального времени адаптируются к изменениям неопределенностей, что обеспечивает примерно одинаковое высокое качество регулирования даже при смене рабочих режимов. Однако использование механизмов адаптации увеличивает вычислительную сложность алгоритмов управления и динамический порядок замкнутой системы, что может привести к запаздыванию при формировании управляющих воздействий.

В данной работе рассматривается проблема синтеза системы управления ориентацией и высотой квадрокоптера при наличии параметрических неопределенностей и при действии на объект внешних возмущений. Эта проблема может быть актуальной при проведении фото- и видеосъемки с оператором БПЛА. Предлагается решать задачу на основе блочного подхода [25] или родственного с ним метода обратного хода [21, 26] и компенсировать неопределенности с помощью построения их наблюдателя. В стандартных подходах как в регуляторе, так и в наблюдателе, используют линейные обратные связи. Однако эти управления могут приводить к перерегулированию и всплескам оценочных сигналов, что критично на практике, когда имеются ограничения на переменные состояния и управления. При этом в рамках метода обратного хода в общем случае можно выполнить заданные ограничения только на выходные переменные с помощью барьерных функций Ляпунова [13]. Для учета ограничений на скорости и ускорения приходится использовать другие методы.

В данной работе для того чтобы комплексно обойти указанные проблемы предлагается использовать гладкие и ограниченные локальные обратные связи в виде гиперболического тангенса, который принадлежит классу сигмовидных функций (сигмоид). Эти обратные связи будут применены при синтезе регулятора и наблюдателя возмущений с учетом особенностей математической модели квадрокоптера. Научная новизна работы состоит в следующем:

1. На основе редуцированной модели, не включающей контуры управления линейными горизонтальными перемещениями, для управления ориентацией и высотой квадрокоптера разработана декомпозиционная процедура синтеза системы слежения. При этом синтез происходит на основе блочного подхода. В результате сформировано комбинированное управление, компенсирующее часть оцениваемых параметрических и внешних возмущений и демпфирующее колебания, возникающие из-за динамики моторов. Стабилизирующая составляющая в виде вложенных сигмовидных функций обеспечивает переходные процессы без большого перерегулирования и подавляет другую часть неопределяемых неопределенностей. Формализована процедура выбора коэффициентов регулятора, обеспечивающих отслеживание выходными переменными эталонных траекторий с заданной точностью и за заданное время. Показано, что компенсация неопределенностей реализуема при параметрически неопределенной входной матрице.

2. Разработан наблюдатель возмущений минимально возможного порядка, позволяющий восстановить внешние возмущения по их воздействию на объект управления без наличия динамической модели возмущений. Оценки неопределенностей предоставляют сигмовидные корректирующие воздействия наблюдателя, что расширяет класс допустимых для оценивания неопределенностей за счет негладких и изменяющихся во времени функций (по сравнению с некоторыми известными техниками компенсации возмущений с помощью наблюдателей или Active Disturbance Rejection Control (ADRC) [16], для реализации которых полагается, что неопределенности являются постоянными). Формализованы неравенства для настройки коэффициентов корректирующих воздействий наблюдателя, обеспечивающих оценивание неопределенностей с заданной точностью и за заданное время без больших всплесков оценочных сигналов, характерных для линейных наблюдателей с большими коэффициентами усиления.

3. Приведены результаты апробации разработанной системы управления на квадрокоптере со стандартной рамой F450 и с полетным контроллером на микросхеме MDR32F9Q2I (производитель «ПКК Миландр»).

4. Приведены результаты сравнительного анализа замкнутых систем с предлагаемыми сигмовидными и классическими линейными стабилизирующими обратными связями при отработке негладких задающих воздействий.

Работа имеет следующую структуру. В разделе 2 представлена математическая модель квадрокоптера, формализована постановка задачи и сформулированы все необходимые предположения для ее решения. В разделе 3 на примере системы второго порядка с согласованными и с несогласованными возмущениями формализована процедура синтеза закона управления в виде вложенных сигмовидных функций. Далее этот подход распространяется для модели квадрокоптера: в разделе 4 разработана модификация блочного подхода с сигмовидными обратными связями для управления ориентацией и высотой квадрокоптера. Для информационного обеспечения сформированного закона управления в разделе 5 описан синтез наблюдателя возмущений. В разделе 6 приведены результаты апробации предложенных алгоритмов управления и наблюдения.

2. Описание математической модели квадрокоптера и постановка задачи. Математическая модель движения симметричного квадрокоптера с четырьмя несущими винтами, рассматриваемого как твердое тело с шестью степенями свободы,

состоит из двух механических подсистем 6-го порядка с четырьмя управлениями: полноприводной подсистемы, описывающей динамику углов Эйлера (подсистема вращательного движения), и связанной с ней подсистемы с дефицитом управлений, описывающей динамику линейных координат (подсистема поступательного движения). В данных моделях учитывается динамика исполнительных устройств, но синтез управления в исполнительных приводах в данной работе не рассматривается.

На рисунке 1 приведены системы координат, в которых измерялись переменные состояния [27]: глобальная неподвижная NED (north – X, east – Y, down – Z) и связанная система координат FRD (front – X, right – Y, down – Z).




Рис. 1. Используемые системы координат

Уравнения динамики объекта представим на основе [28], но с учетом сил аэродинамического сопротивления [29] и действия на объект внешних возмущений:

$$\ddot{\bar{\eta}} = \bar{F}(\bar{\eta}, \dot{\bar{\eta}}, t) + \bar{B}(\bar{\eta})\bar{u}, \quad (1)$$

$$\begin{aligned} \ddot{x} &= -\frac{r_4}{m} \dot{x} + (c_\phi s_\theta c_\psi + s_\phi s_\psi) \frac{u_z}{m}, \\ \ddot{y} &= -\frac{r_5}{m} \dot{y} + (c_\phi s_\theta s_\psi - s_\phi c_\psi) \frac{u_z}{m}, \\ \ddot{z} &= -\frac{r_6}{m} \dot{z} + g + c_\phi c_\theta \frac{u_z}{m}, \end{aligned} \quad (2)$$

где $\bar{\eta} = (\phi, \theta, \psi)^T$ – вектор ориентации, ϕ – крен, $-\pi/2 < \phi(t) < \pi/2$, $t \geq 0$, θ – тангаж, $-\pi/2 < \theta(t) < \pi/2$, $t \geq 0$, ψ – рыскание; $\dot{\bar{\eta}} = (\dot{\phi}, \dot{\theta}, \dot{\psi})^T$, $\ddot{\bar{\eta}} = (\ddot{\phi}, \ddot{\theta}, \ddot{\psi})^T$ – векторы угловых скоростей и ускорений соответственно, заданных в NED (рисунок 1).

Связь угловых скоростей в FRD и NED определяется уравнением кинематики:

$$\dot{\bar{\eta}} = R(\bar{\eta})\dot{\bar{\eta}}_{\text{FRD}}, \quad (3)$$

где $\dot{\bar{\eta}}_{\text{FRD}} = (p, q, r)^T \in R^{3 \times 1}$ – вектор угловых скоростей в FRD, которые

измеряются с помощью гироскопа, $R(\bar{\eta}) = \begin{bmatrix} 1 & s_\phi t_\theta & c_\phi t_\theta \\ 0 & c_\phi & -s_\phi \\ 0 & s_\phi / c_\theta & c_\phi / c_\theta \end{bmatrix}$ –

матрица поворота, $s_* = \sin(*)$, $c_* = \cos(*)$, $t_* = \text{tg}(*)$. При этом уравнения динамики в FRD имеют вид:

$$\ddot{\bar{\eta}}_{\text{FRD}} = (\bar{F}_p, \bar{F}_q, \bar{F}_r)^T + \text{diag}(1/I_1, 1/I_2, 1/I_3)\bar{u}, \quad (4)$$

где вектор-функции $\bar{F}_p$, $\bar{F}_q$, $\bar{F}_r$ определяют динамику объекта в FRD, I_i – главные моменты инерции, $i = 1, 2, 3$.

Тогда с помощью дифференцирования (3) получаем, что в (1) вектор-функция $\bar{F}(\bar{\eta}, \dot{\bar{\eta}}, t) = (\bar{F}_1, \bar{F}_2, \bar{F}_3)$ составлена с учетом преобразования (4) из FRD в NED, а именно $\bar{F}(\bar{\eta}, \dot{\bar{\eta}}, t) = R(\bar{\eta}) \cdot (\bar{F}_p, \bar{F}_q, \bar{F}_r)^T + \dot{R}(\bar{\eta}, \dot{\bar{\eta}})\dot{\bar{\eta}}_{\text{FRD}}$, где

$$\dot{R}(\bar{\eta}, \dot{\bar{\eta}}) = \begin{bmatrix} 0 & c_\phi t_\theta \dot{\phi} + (s_\phi \dot{\theta}) / (c_\theta^2) & -s_\phi t_\theta \dot{\phi} + (c_\phi \dot{\theta}) / (c_\theta^2) \\ 0 & -s_\phi \dot{\phi} & -c_\phi \dot{\phi} \\ 0 & (c_\phi c_\theta \dot{\phi} + s_\phi s_\theta \dot{\theta}) / (c_\theta^2) & (-s_\phi c_\theta \dot{\phi} + c_\phi s_\theta \dot{\theta}) / (c_\theta^2) \end{bmatrix}.$$

Элементы $\bar{F}_p$, $\bar{F}_q$, $\bar{F}_r$ соответствуют системе координат FRD.

Они зависят от неопределенных параметров объекта управления, внешних возмущений и имеют следующий вид:

$$\begin{aligned}\bar{F}_p &= -\frac{r_1}{I_1} p^2 + \frac{I_2 - I_3}{I_1} q r + f_1(t), \quad \bar{F}_q = -\frac{r_2}{I_2} q^2 + \frac{I_3 - I_1}{I_2} p r + f_2(t), \\ \bar{F}_r &= -\frac{r_3}{I_3} r^2 + \frac{I_1 - I_2}{I_3} p q + f_3(t),\end{aligned}\quad (5)$$

где $f_i(t)$ – внешние возмущения, которые также включают неучтенные силы и моменты, $r_i > 0$ – коэффициенты аэродинамического сопротивления, $i = 1, 2, 3$.

Матрица управления $\bar{B}(\bar{\eta})$ определяется произведением матрицы поворота на обратную матрицу к матрице инерции:

$$\bar{B}(\bar{\eta}) = R(\bar{\eta}) \cdot \text{diag}(1/I_1, 1/I_2, 1/I_3). \quad (6)$$

Управлением в полноприводной подсистеме ориентации (1) является вектор моментов $\bar{u} = (\tau_p, \tau_q, \tau_r)^T$.

Переменные состояния подсистемы (2) с дефицитом управлений – это линейные координаты x , y и высота z , измеряемые в неподвижной системе координат NED (рисунок 1); m – масса квадрокоптера, g – ускорение свободного падения; $r_i > 0$ – коэффициенты аэродинамического сопротивления, $i = 4, 5, 6$; u_z – управляющая суммарная тяга.

В данной работе выходными (регулируемыми) переменными являются углы Эйлера $\phi(t)$, $\theta(t)$, $\psi(t)$ и высота $z(t)$, для которых имеются «свои» истинные управления. При управлении углами Эйлера и высотой дифференциальные уравнения для линейных координат x , y (2) рассматриваются как уравнения нулевой динамики. Из (2) следует, что, если начиная с некоторого момента времени t_0 , выполняется $\phi(t) = 0$, $\theta(t) = 0$, то уравнения нулевой динамики принимают вид:

$$\ddot{x} = -\frac{r_4}{m} \dot{x}, \quad \ddot{y} = -\frac{r_5}{m} \dot{y}.$$

Решением этой системы являются следующие функции:

$$x(t) = \frac{r_4 x(t_0) + m \dot{x}(t_0)(1 - \exp(-r_4 t / m))}{r_4},$$

$$y(t) = \frac{r_5 y(t_0) + m \dot{y}(t_0)(1 - \exp(-r_5 t / m))}{r_5}.$$

Следовательно, при $\phi(t) = 0$, $\theta(t) = 0$ квадрокоптер начинает тормозить в горизонтальной плоскости и стабилизируется в положении неустойчивого равновесия $x(t_0) + m[\dot{x}(t_0)/r_4]$, $y(t_0) + m[\dot{y}(t_0)]/r_5$. Решение задачи регулирования линейных координат не является предметом исследования в данной работе. Однако для предотвращения сильного изменения $x(t)$ и $y(t)$ поставим задачу синтеза управлений τ_p , τ_q , τ_r и u_z в форме динамических обратных связей так, чтобы высота и рыскание отслеживали эталонные траектории с заданной точностью при стабилизации нулевых углов крена и тангажа:

$$|\phi(t)| \leq \delta_{11}, |\theta(t)| \leq \delta_{12}, |\psi(t) - \psi_{\text{des}}(t)| \leq \delta_{13}, |z(t) - z_{\text{des}}(t)| \leq \delta_{14}, \quad (7)$$

где $\psi_{\text{des}}(t)$, $z_{\text{des}}(t)$ – эталонные траектории, δ_{1i} – желаемые значения ошибок слежения в установившемся режиме, $i = 1, \dots, 4$.

В этом случае допустимо убрать из рассмотрения уравнения динамики линейных координат $x(t)$, $y(t)$ (2), а управление ориентацией и высотой осуществлять на основе редуцированной системы, которая включает подсистему (1) и третье уравнение подсистемы (2):

$$\dot{\eta}_1 = \eta_2, \quad \dot{\eta}_2 = F_0 + F_1(\eta_1, \eta_2, t) + B_0(\bar{\eta})u, \quad (8)$$

где $\eta_1 = (\phi, \theta, \psi, z)^T$ – вектор регулируемых переменных, $\eta_2 = (\dot{\phi}, \dot{\theta}, \dot{\psi}, \dot{z})^T$ – вектор скоростей объекта в NED. Вектор $F_0 = (0, 0, 0, g)^T$ содержит известную часть модели (8), которую можно компенсировать с помощью управления $u = (\tau_p, \tau_q, \tau_r, u_z)^T$. Ненулевая компонента вектора F_0 включает один параметр – ускорение свободного падения g . Вектор-функция $F_1(\eta_1, \eta_2, t)$ состоит из

неопределенностей модели, ее компоненты и выражение для номинальной матрицы управления $B_0(\bar{\eta})$ будут приведены далее.

Матрица управления $B(\bar{\eta})$ зависит от углов Эйлера $\bar{\eta}$ и от параметров объекта, включающих неопределенности (моментов инерции и массы квадрокоптера). Она имеет блочную структуру

$$B(\bar{\eta}) = \begin{pmatrix} B_1(\bar{\eta}) & O_1 \\ O_2 & B_2(\bar{\eta}) \end{pmatrix} \in R^{4 \times 4}, \quad \text{где} \quad B_1(\bar{\eta}) = \bar{B}(\bar{\eta}) \in R^{3 \times 3} \quad (6),$$

$O_1 = (0, 0, 0)^T$, $O_2 = (0, 0, 0)$, $B_2(\bar{\eta}) = \frac{c_\phi c_\theta}{m}$. При этом данную матрицу можно записать в виде суммы двух составляющих [25]:

$$B(\bar{\eta}) = B_0(\bar{\eta}) + \Delta B(\bar{\eta}), \quad \text{rank} B = \text{rank} B_0, \quad \|\Delta B B_0^{-1}\| < 1, \quad (9)$$

где $B_0(\bar{\eta}) = \begin{pmatrix} B_{01}(\bar{\eta}) & O_1 \\ O_2 & B_{02}(\bar{\eta}) \end{pmatrix} \in R^{4 \times 4}$ – известная номинальная часть,

в которой блоки определяются следующими выражениями:

$$B_{01}(\bar{\eta}) = R(\bar{\eta}) \cdot \text{diag} \left(\frac{1}{I_{01}}, \frac{1}{I_{02}}, \frac{1}{I_{03}} \right) \in R^{3 \times 3}, \quad B_{02}(\bar{\eta}) = \frac{c_\phi c_\theta}{m_0} \in R^{1 \times 1}.$$

Здесь моменты инерции $I_i = I_{0i} + \Delta I_i$ и массу квадрокоптера $m = m_0 + \Delta m$ также представили в виде суммы двух составляющих, из которых I_{0i} , m_0 – номинальные, ΔI_i , Δm – неопределенные, $i = 1, 2, 3$.

Неопределенная часть матрицы управления

$$\Delta B(\bar{\eta}) = \begin{pmatrix} \Delta B_1(\bar{\eta}) & O_1 \\ O_2 & \Delta B_2(\bar{\eta}) \end{pmatrix} \in R^{4 \times 4} \quad \text{включает следующие блоки:}$$

$$\begin{aligned} \Delta B_1(\bar{\eta}) &= -R(\bar{\eta}) \cdot \text{diag} \left(\frac{\Delta I_i}{I_{0i}(I_{0i} + \Delta I_i)} \right) \in R^{3 \times 3}, \\ \Delta B_2(\bar{\eta}) &= - \frac{\Delta m c_\phi c_\theta}{m_0(m_0 + \Delta m)} \in R^{1 \times 1}. \end{aligned} \quad (10)$$

Произведение этой неопределенной части $\Delta B(\bar{\eta})$ на управление $u = (\tau_p, \tau_q, \tau_r, u_z)^T$ вошло в вектор функцию $F_1(\eta_1, \eta_2, t) = (F_{11}, F_{12}, F_{13}, F_{14})^T$, которая описывает все неопределенности модели в системе координат NED. В силу (2), (5) ее компоненты имеют вид:

$$(F_{11}, F_{12}, F_{13})^T = \bar{F} + \Delta B_1(\bar{\eta})\bar{u}, \quad F_{14} = -\frac{r_6}{m}\dot{z} + \Delta B_2(\bar{\eta})u_z. \quad (11)$$

Приведем все предположения, выдвигаемые при решении задачи (7).

1. Элементами вне диагонали матрицы инерции пренебрегаем в силу их существенной малости по отношению к главным моментам инерции.

2. Известны номинальные значения главных моментов инерции I_{0i} , $i = 1, 2, 3$ и значение массы квадрокоптера m_0 .

3. Неопределенности $F_1(\eta_1, \eta_2, t)$ в (8) изменяются в допустимых областях:

$$|F_{li}(\eta_1, \eta_2, t)| \leq \bar{F}_{li}, \quad t \geq 0, \quad i = 1, \dots, 4, \quad (12)$$

где $\bar{F}_{li}$ – известные константы, $i = 1, \dots, 4$.

4. Задающие воздействия $\eta_{i,\text{des}}(t) = (0, 0, \psi_{\text{des}}(t), z_{\text{des}}(t))^T$ могут быть кусочно-непрерывными ограниченными функциями с конечным числом точек разрыва первого рода:

$$|\dot{\eta}_{li,\text{des}}(t)| \leq H_{i,\text{des}}, \quad i = 1, \dots, 4, \quad (13)$$

где $H_{i,\text{des}}$ – известные константы, $i = 1, \dots, 4$. Для обобщенной производной ограничения вида (13) понимаются как односторонние.

5. Задача управления исполнительными приводами в данной работе не рассматривается. Для управления угловыми скоростями вращения моторов предполагается использовать широтно-импульсную модуляцию (ШИМ) и стандартный регулятор. При этом сформированные в механической подсистеме управляющие силы и моменты будут пересчитаны в ШИМ-сигналы на основе

приближенной нелинейной зависимости, полученной экспериментально (подробнее это будет описано в разделе 6 с результатами апробации алгоритмов).

6. Для синтеза управления в силу измерений и их математических преобразований доступны все переменные состояния η_1, η_2 , а также ускорения $\dot{\eta}_2 = (\ddot{\phi}, \ddot{\theta}, \ddot{\psi}, \ddot{z})^T$ (описание датчиков будет представлено в разделе 6 с результатами апробации алгоритмов). При этом предполагается, что датчики имеют высокое разрешение.

Отметим, что аналитический вид неопределенной матрицы управления $\Delta B(\bar{\eta})$ (10) был приведен лишь для наглядности демонстрации, как можно разделить матрицу управления на сумму известной и неизвестной части (9). Для реализации алгоритмов синтеза управлений, которые будут предложены в следующем разделе, знать аналитический вид этих матриц и составляющих $F_1(\eta_1, \eta_2, t)$ (11) будет непринципиально. Достаточно будет ограниченности неопределенностей, т.е. выполнения условия (12).

3. Предварительные сведения для синтеза системы слежения. Для упрощения дальнейшей демонстрации основных результатов работы рассмотрим синтез предлагаемых алгоритмов управления на примере следующей системы второго порядка, на которую действуют внешние несогласованные и согласованные возмущения:

$$\dot{x}_1 = x_2 + d_1(t), \quad \dot{x}_2 = f(x) + d_2(t) + v, \quad (14)$$

где $x = (x_1, x_2)^T \in X \subset R^2$ – известный вектор состояния (его компоненты измеряются), $x_1 \in R$ – выход, $v \in R$ – управление, $d_1(t)$ – несогласованные внешние возмущения, $d_2(t)$ – согласованные внешние возмущения, $f(x)$ – известная функция, описывающая динамику модели. Полагаем, что неизвестные внешние возмущения $d_1(t)$, $d_2(t)$ могут быть негладкими, но они ограничены известными константами:

$$|d_i(t)| \leq D_i, \quad i = 1, 2, \quad t \geq 0. \quad (15)$$

Отметим, что системой (14) может быть описана динамика ошибки слежения при решении задачи управления квадрокоптером,

где x_1 – это невязка между одной из выходных переменных (углом Эйлера или высотой) и желаемой траекторией ее изменения (ошибка слежения). При этом производная данной траектории аддитивно входит во внешние несогласованные возмущения $d_1(t)$ и может быть негладкой. Переменная x_2 представляет собой вторую производную одной из выходных переменных объекта.

При наличии в модели (14) незатухающих внешних возмущений задача управления переменной x_1 может быть решена только с заданной точностью:

$$|x_1(t)| \leq \delta_1, \quad t \geq t_1. \quad (16)$$

Для удобства синтеза управления v , обеспечивающего (16), воспользуемся блочным принципом управления [25]. Использование виртуального и истинного управления в виде ограниченных сигмовидных функций [25, 30, 31] позволит уменьшить перегулирование и подавить внешние возмущения.

Введем замену переменных:

$$e_1 = x_1, \quad e_2 = x_2 - x_2^* = x_2 + m_1 \tanh(k_1 e_1), \quad (17)$$

где e_2 – невязка между реальным x_2 и сформированным виртуальным управлением $x_2^* = -m_1 \tanh(k_1 e_1)$, $m_1 = \text{const} > 0$, $k_1 = \text{const} > 0$, стабилизирующим ошибку слежения e_1 . В результате приходим к системе в невязках, замкнутой локальными связями:

$$\dot{e}_1 = e_2 + d_1(t) - m_1 \tanh(k_1 e_1), \quad \dot{e}_2 = f(x) + v + \tilde{d}_2(t), \quad (18)$$

где $\tilde{d}_2(t) = d_2(t) + \Lambda(t)$, $\Lambda(t)$ – производная гиперболического тангенса, которая возникает при дифференцировании e_2 :

$$\Lambda(t) = d(m_1 \tanh(k_1 e_1)) / dt = m_1 k_1 (1 - \tanh^2(k_1 e_1)) \dot{e}_1. \quad (19)$$

В силу консервативной оценки $|\dot{e}_1(t)| \leq 2m_1$, $t \geq 0$ эта производная (19) является ограниченной:

$$|\Lambda(t)| \leq m_1 k_1 |\dot{e}_1|, \quad |\dot{e}_1(t)| \leq 2m_1, \quad t \geq 0 \Rightarrow |\Lambda(t)| \leq 2m_1^2 k_1. \quad (20)$$

Тогда функцию $\tilde{d}_2(t)$ в (18) будем считать новым возмущением, которое ограничено в силу (15), (20):

$$|\tilde{d}_2(t)| \leq D_2 + 2m_1^2 k_1, \quad t \geq 0. \quad (21)$$

Закон истинного управления ν примем в виде обратной связи по переменным состояния:

$$\begin{aligned} \nu &= -(f(x) + m_2 \tanh(k_2 e_2) + k_3 \dot{x}_2) = \\ &= -(f(x) + m_2 \tanh(k_2(x_2 + m_1 \tanh(k_1 x_1)))) + k_3 \dot{x}_2, \end{aligned} \quad (22)$$

где $m_2 > 0$, $k_2 > 0$, $k_3 \geq 0$ – константы. В законе управления (22) часть $-m_2 \tanh(k_2 e_2)$ с гиперболическим тангенсом служит для стабилизации невязки e_2 [25]. По сравнению с [25] в закон управления (22) введена часть $-k_3 \dot{x}_2$, предназначенная для уменьшения колебаний регулируемой переменной x_1 из-за неопределенной динамики объекта (внешних возмущений).

В результате с учетом $\dot{x}_2 = \Lambda(t) - \dot{e}_2$ (14), (18) приходим к замкнутой системе (18), (22):

$$\dot{e}_1 = e_2 + d_1(t) - m_1 \tanh(k_1 e_1), \quad \dot{e}_2 = -\frac{m_2}{1+k_3} \tanh(k_2 e_2) + \frac{k_3 \tilde{d}_2(t)}{1+k_3}. \quad (23)$$

Сформулируем достаточные условия устойчивости замкнутой системы (23), не принимая во внимание время сходимости, которое зависит от начальных условий.

Лемма 1. Если в системе (21) выполняются условия $|d_i(t)| \leq D_i$, $i = 1, 2$, $t \geq 0$ (15), то тогда для любого $\delta_1 > 0$ существуют такие значения $\underline{m}_1 > 0$, $\underline{m}_2 > 0$, $\underline{k}_1 > 0$, $\underline{k}_2 > 0$, что при любых $m_1 > \underline{m}_1$, $k_1 \geq \underline{k}_1$, $m_2 > \underline{m}_2$, $k_2 \geq \underline{k}_2$, $k_3 \geq 0$, начиная с некоторого момента времени $t > t_1$ выполняется $|e_1(t)| \leq \delta_1$ (16).

Доказательство Леммы 1. Для гиперболического тангенса $\tanh(k_i e_i)$ и его первой производной, зависящих от аргумента $k_i e_i$, $k_i > 0$, в силу связи с логистической функцией $\tanh(k_i e_i) = \sigma(k_i e_i / 2)$, $\sigma(k_i e_i) = 2 / (1 + \exp(-k_i e_i)) - 1$ справедливы следующие оценки [25]:

$$\begin{aligned} 0.76 < |\tanh(k_i e_i)| < 1, \quad 0 < \tanh'(k_i e_i) \leq 0.42 k_i, \quad |e_i| > 1 / k_i; \\ 0.76 k_i |e_i| \leq |\tanh(k_i e_i)| \leq 0.76, \quad 0.42 k_i < \tanh'(k_i e_i) \leq k_i, \quad |e_i| \leq 1 / k_i, \end{aligned} \quad (24)$$

где в области $|e_i| \leq 1 / k_i$ функцию $\tanh(k_i e_i)$ можно приблизить линейной функцией, а в области $|e_i| > 1 / k_i$ – приблизить константой.

Согласно идеологии блочного подхода в замкнутой системе (21) нужно обеспечить последовательную сходимость невязок в окрестности нуля $|e_2(t)| \leq \delta_2$ ($t > t_2 \geq 0$) $\Rightarrow$ $|e_1(t)| \leq \delta_1$ ($t > t_1 > t_2$), где δ_1 – задано, δ_2 назначается произвольно. Учитывая обратную зависимость радиуса сходимости от коэффициента усиления (22), сразу зафиксируем их нижние оценки на основе неравенств

$$k_1 \geq \underline{k}_1 = 1 / \delta_1 > 0, \quad k_2 \geq \underline{k}_2 = 1 / \delta_2 > 0. \quad (25)$$

Сходимость невязок в области $|e_i| \leq 1 / k_i \leq \delta_i$ обеспечивается выбором амплитуд m_i , $i = 1, 2$, нижние оценки для которых найдем с помощью второго метода Ляпунова. Введем следующую функцию в качестве кандидата на функцию Ляпунова замкнутой системы (23):

$$V = V_1 + V_2, \quad V_1 = 0.5 e_1^2, \quad V_2 = 0.5 e_2^2. \quad (26)$$

Используя (21) и (24), при $|e_2| > 1 / k_2$ оценки производных слагаемого V_2 в силу системы (23) имеют вид:

$$\dot{V}_2(t) = e_2 \dot{e}_2 \leq |e_2(t)| (1 + k_3)^{-1} (-0.76 m_2 + k_3 (D_2 + 2 m_1^2 k_1)).$$

Тогда при $m_2 > 1.32 k_3 (D_2 + m_1^2 k_1)$ выполняется $\dot{V}_2 < 0$, и за некоторое время $t > t_2 \geq 0$ ошибка слежения e_2 попадает в

окрестность $|e_2| \leq 1/k_2$ и далее остается в ней. Используя (15) и (24), при $|e_2| \leq 1/k_2 \leq \delta_2$ и $|e_1| > 1/k_1$ находим, что справедливы следующие оценки производных слагаемого V_1 в силу системы (23):

$$\dot{V}_1(t) = e_1 \dot{e}_1 \leq |e_1(t)|(\delta_2 + D_1 - 0.76m_1).$$

Следовательно, при $m_1 > 1.32(1/k_2 + D_1)$ выполняется $\dot{V}_1 < 0$, и за некоторое время $t > t_1 > t_2$ ошибка слежения e_1 попадает в окрестность $|e_1| \leq 1/k_1 \leq \delta_1$.

Таким образом, получены такие нижние оценки для выбора коэффициентов усиления (25) и амплитуд $\underline{m}_1 = 1.32(\delta_2 + D_1) > 0$, $\underline{m}_2 = 1.32k_3(D_2 + m_1^2 k_1)$, что при любых $m_1 > \underline{m}_1$, $m_2 > \underline{m}_2$, $k_1 \geq \underline{k}_1$, $k_2 \geq \underline{k}_2$, $k_3 \geq 0$ функция $V = V_1 + V_2$ (26) является функцией Ляпунова замкнутой системы (23), и начиная с некоторого момента времени $t > t_1$ выполняется $|e_1(t)| \leq \delta_1$ (16). Лемма 1 доказана.

Покажем, что за счет выбора коэффициентов регулятора также можно обеспечить желаемое время t_2 , t_1 сходимости невязок e_2 , e_1 соответственно:

$$|e_2(t)| \leq \delta_2, t > t_2, |e_1(t)| \leq \delta_1, t > t_1 > t_2. \quad (27)$$

Введем обозначения для максимального значения модулей невязок:

$$|e_1(t)| \leq e_{1,\max}, |e_2(t)| \leq e_{2,\max}, t \geq 0.$$

Для этих значений справедливы оценки:

$$e_{1,\max} = |e_1(0)| + (e_{2,\max} - \delta_2)t_2, e_{2,\max} = |x_2(0)| + m_1. \quad (28)$$

С учетом оценок (28), если выполняются условия

$$2(|x_2(0)| - \delta_2) \leq m_1 \leq 0.66(E_1 - |e_1(0)|) / t_2, \quad (29)$$

то невязки будут ограничены

$$e_{1,\max} \leq E_1, e_{2,\max} \leq 1.5m_1 + \delta_2,$$

где $E_1 > 0$ – желаемая граница изменения модуля невязки e_1 .

При заданной ошибке $\delta_1 > 0$ зафиксируем некоторые значения $E_1^* > 0$, $\delta_2^* > 0$, $k_2^* : k_2 > 1/\delta_2^*$ и $k_3^* \geq 0$. Далее формализуем процедуру выбора амплитуд m_1 , m_2 , которая обеспечит желаемое время сходимости невязок (27). Эта процедура будет состоять из двух шагов.

Шаг 1. Определим амплитуду m_1 . Учет времени сходимости ошибки слежения приводит к повышению нижней границы на выбор амплитуды по сравнению с границей $\underline{m}_1 = 1.32(\delta_2 + D_1) > 0$ из Леммы 1, где время не учитывалось. При $|e_2(t)| \leq \delta_2$, $t > t_2$ условия на выбор m_1 примут следующий вид:

$$\begin{aligned} 0.76m_1 &> \frac{|e_1(0)| + 1.5m_1t_2 - \delta_1}{t_1 - t_2} + \delta_2 + D_1 \Rightarrow \\ \Rightarrow m_1 &> \frac{|e_1(0)| - \delta_1 + (\delta_2 + D_1)(t_1 - t_2)}{0.76t_1 - 2.26t_2}. \end{aligned}$$

Из этих условий также следует ограничение на выбор t_2 :

$$0.76t_1 - 2.26t_2 > 0 \Rightarrow 0 < t_2 < 0.336t_1. \quad (30)$$

Тогда фиксируем t_2^* из (30) и, используя (29), определяем границы допустимого выбора m_1 :

$$\underline{m}_1 < m_1 < \overline{m}_1, \quad (31)$$

где

$$\begin{aligned} \underline{m}_1 &= \max\{\underline{m}_{11}, \underline{m}_{12}\}, \\ \underline{m}_{11} &= 2(|x_2(0)| - \delta_2), \\ \underline{m}_{12} &= \frac{|e_1(0)| - \delta_1 + (\delta_2 + D_1)(t_1 - t_2)}{0.76t_1 - 2.26t_2}, \quad \overline{m}_1 = 0.66(E_1 - |e_1(0)|) / t_2. \end{aligned} \quad (32)$$

Если $\overline{m}_1 > \underline{m}_1$, то фиксируем m_1^* из (31), (32). В противном случае назначаем новое $E_1^* : E_1 > (1.5\underline{m}_1 + |e_1(0)|)t_2^*$, которое обеспечит выполнение $\overline{m}_1 > \underline{m}_1$ и позволит зафиксировать некоторое значение m_1^* из (31), (32). После назначения m_1^* переходим на второй шаг процедуры.

Шаг 2. Фиксируем значение m_2^* из условия:

$$(1 + k_3^*)^{-1} m_2 > 1.32 \left(\frac{|x_2(0)| + m_1^* - \delta_2^*}{t_2^*} + k_3^* \left(D_2 + 2(m_1^*)^2 k_1^* \right) \right).$$

На этом процедура выбора амплитуд заканчивается. Заметим, что сначала фиксируется амплитуда m_1^* , которая призвана стабилизировать невязку e_1 , затем амплитуда m_2^* для обеспечения стабилизации e_2 с заданной точностью и за заданное время. При этом невязки сходятся в обратном порядке: сначала стабилизируется e_2 , затем e_1 согласно (27).

Разработанная процедура выбора амплитуд регулятора основывалась на консервативных оценках, поэтому нижние границы на выбор амплитуд не являются наименьшими, при которых достигается устойчивость замкнутой системы. При этом избыточность оценок может приводить к нарушению ограничений на переменные состояния и управления, которые имеются на практике. Из-за этого разработанная процедура может служить лишь для получения опорных значений коэффициентов регулятора для численного моделирования. Затем значения коэффициентов регулятора корректируются (уменьшаются) относительно опорных посредством численного моделирования для дальнейшей апробации алгоритмов на реальном объекте.

В следующем разделе предложенный алгоритм управления будет распространен на систему большего порядка, описывающую динамику квадрокоптера.

4. Синтез базовых законов управления. Сначала в рамках блочного принципа управления рассмотрим синтез так называемого базового закона управления, который предполагает полную определенность математической модели объекта управления (т.е. будем считать, что помимо F_0 в (8) известны все параметры объекта и известны внешние возмущения $F_1(\eta_1, \eta_2, t)$). Далее для получения оценок $F_1(\eta_1, \eta_2, t)$ будет предложен наблюдатель возмущений [17, 18], который позволит построить комбинированное управление при наличии неопределенностей в модели объекта.

Для реализации блочного принципа управления будем трактовать переменную η_2 в первом уравнении системы (8) как виртуальное управление. Тогда по аналогии с (17), (22) введем следующую замену переменных и базовый закон управления:

$$\begin{aligned} e_1 &= \eta_1 - \eta_{1,\text{des}}(t), \quad e_2 = \eta_2 + M_1 \tanh(K_1 e_1), \\ u &= -B_0^{-1}(\bar{\eta})(F_0 + \tilde{F}_1(\eta_1, \eta_2, t) + M_2 \tanh(K_2 e_2) + K_3 \ddot{\eta}_1), \end{aligned} \quad (33)$$

где $M_i \tanh(K_i e_i) = (m_{i1} \tanh(k_{i1} e_{i1}), \dots, m_{i4} \tanh(k_{i4} e_{i4}))^T$, $m_{ij} > 0$, $k_{ij} > 0$, $i = 1, 2$, $j = 1, \dots, 4$, $K_3 = \text{diag}(k_{3i})$, $k_{3i} \geq 0$, $i = 1, \dots, 4$.

Замкнутая система имеет схожий с (23) вид:

$$\begin{aligned} \dot{e}_1 &= e_2 - \dot{\eta}_{1,\text{des}}(t) - M_1 \tanh(K_1 e_1), \\ \dot{e}_2 &= -(I + K_3)^{-1} M_2 \tanh(K_2 e_2) + (I + K_3)^{-1} K_3 \Lambda(t), \end{aligned} \quad (34)$$

где I – единичная матрица $\dot{\eta}_{1,\text{des}} = (0, 0, \dot{\psi}_{\text{des}}(t), \dot{z}_{\text{des}}(t))^T$ – вектор-функция производных задающих воздействий, $\tilde{F}_1(\eta_1, \eta_2, t) = F_1(\eta_1, \eta_2, t) + \Lambda(t)$ – новые неопределенности, $\Lambda(t) = (\Lambda_1(t), \dots, \Lambda_4(t))^T$ – вектор-функция из производных гиперболического тангенса в силу системы (34):

$$\Lambda_i(t) = d(m_{li} \tanh(k_{li} e_{li})) / dt = m_{li} k_{li} (1 - \tanh^2(k_{li} e_{li})) \dot{e}_{li}, \quad i = 1, \dots, 4.$$

Эти компоненты ограничены аналогично (20):

$$\begin{aligned} |\Lambda_i(t)| &\leq m_{li} k_{li} |\dot{e}_{li}|, \quad |\dot{e}_{li}(t)| \leq 2m_{li}, \quad t \geq 0 \Rightarrow \\ \Rightarrow |\Lambda_i(t)| &\leq 2m_{li}^2 k_{li}, \quad i = 1, \dots, 4. \end{aligned} \quad (35)$$

Из (12) и (35) следует, что компоненты новых неопределенностей $\tilde{F}_1(\eta_1, \eta_2, t)$ также ограничены:

$$|\tilde{F}_{li}(\eta_1, \eta_2, t)| \leq \bar{F}_{li} + 2m_{li}^2 k_{li}, \quad i = 1, \dots, 4. \quad (36)$$

Тогда вектор-функцию $\tilde{F}_1(\eta_1, \eta_2, t)$ можно трактовать как согласованное возмущение, а производные задающих воздействий $\dot{\eta}_{1,des}$ – как несогласованные возмущения. При этом все возмущения ограничены в силу (13) и (36). Следовательно, для каждой компоненты системы (34) справедлива Лемма 1, и существуют коэффициенты регулятора m_{li} , k_{li} , m_{2i} , k_{2i} , k_{3i} , обеспечивающие цель управления – стабилизацию e_{li} с заданной величиной ошибки в установившемся режиме (7). Кроме того, для достижения сходимости ошибок слежения e_{li} , $i = 1, \dots, 4$ за заданное время можно использовать процедуру настройки коэффициентов регулятора, представленную в разделе 3.

Предложенный закон управления (33) является модификацией [25], в которую введена часть $-K_3 \ddot{\eta}_1$ с ускорениями объекта для уменьшения колебаний регулируемых переменных η_1 . Проблема их сильных колебаний вызвана условиями функционирования квадрокоптера и его конструктивными особенностями (гибкой рамой, несбалансированностью пропеллеров и двигателей, динамикой моторов). При этом чем больше значение коэффициента k_{3i} при ускорении, тем меньше амплитуда колебаний соответствующей переменной. Однако из (33), (34) следует, что вместе с этим увеличивается амплитуда управления, увеличивается степень зашумленности сигналов и уменьшается коэффициент при стабилизирующей части $\tanh(k_{2i} e_{2i})$ в замкнутой системе (34), что может привести к появлению перерегулирования. Таким образом, для практической реализации алгоритмов должно быть выбрано некоторое компромиссное значение $k_{3i} \geq 0$, $i = 1, \dots, 4$.

Как правило, сигмиды применяют для учета ограничений на управления. Однако в законе (33) помимо ограниченных сигмовидных частей также присутствует линейная часть $-K_3 \ddot{\eta}_1$ от ускорений

объекта $\ddot{\eta}_1$. Следовательно, этот факт не позволяет учесть ограничения на управляющие воздействия на стадии синтеза системы управления. Далее при программной реализации алгоритма управления будет применена функция насыщения, чтобы избежать выхода ШИМ-сигналов за допустимые диапазоны изменения (подробнее это будет описано в разделе 6 с результатами апробации алгоритма управления).

В данном разделе на основе блочного принципа управления с использованием сигмовидных обратных связей были разработаны базовые законы управления углами Эйлера и высотой. По сравнению со стандартным блочным подходом с линейными виртуальными управлениями, ввод ограниченных и гладких сигмовидных обратных связей позволяет избегать большого перерегулирования. Описана возможность настройки коэффициентов регулятора, обеспечивающей отслеживание выходными переменными объекта эталонных траекторий с заданной величиной ошибки в установившемся режиме и с заданным временем переходного процесса.

В следующем разделе будет синтезирован наблюдатель неопределенностей, на основе которого будет осуществлена компенсация неизвестных параметров и внешних возмущений и реализация построенного базового закона управления.

5. Синтез наблюдателя неопределенностей. Для реализации базового закона управления (33) требуется оценить неопределенности $\tilde{F}_1(\eta_1, \eta_2, t)$. Оценки неопределенностей для их последующей компенсации с помощью комбинированного управления [17, 18] получают с помощью наблюдателя неопределенностей (наблюдателя возмущений [19, 20]). Далее для построения наблюдателя неопределенностей снова применим блочный принцип управления с использованием сигмовидных функций [25]. В данном случае ограниченные гладкие обратные связи позволят уменьшить всплески оценочных сигналов по сравнению со стандартными линейными функциями и наблюдателями с линейными корректирующими воздействиями с большими коэффициентами усиления [32]. Кроме того, в отличие от стандартных подходов, оценку неопределенностей предоставят корректирующие воздействия наблюдателя. Данный подход не требует ввода динамических генераторов возмущений, приводит к построению наблюдателя минимально возможного порядка [25] и к появлению возможности оценивать неопределенности не только в виде констант [16], но и в виде изменяющихся во времени негладких функций. Наблюдатель неопределенностей будем строить

на основе замкнутого локальной связью $\eta_2 = e_2 - M_1 \tanh(K_1 e_1)$ второго уравнения (8):

$$\dot{e}_2 = F_0 + \tilde{F}_1(\eta_1, \eta_2, t) + B_0(\bar{\eta})u. \quad (37)$$

Этот наблюдатель имеет вид [25]:

$$\dot{\hat{e}}_2 = F_0 + B_0(\bar{\eta})u + v, \quad (38)$$

где $\hat{e}_2 \in R^{4 \times 1}$ – вектор состояния наблюдателя, $v \in R^{4 \times 1}$ – вектор корректирующих воздействий.

Введем вектор ошибок наблюдения $\varepsilon = e_2 - \hat{e}_2$ и, используя (37), (38), составим уравнения, описывающие динамику ошибок:

$$\dot{\varepsilon} = \tilde{F}_1(\eta_1, \eta_2, t) - v.$$

Для обеспечения стабилизации ошибок наблюдения корректирующие воздействия v выбираем в виде сигмовидных функций, зависящих от ε [25]:

$$v(\varepsilon) = P \tanh(L\varepsilon), \quad (39)$$

где $P \tanh(L\varepsilon) = (p_1 \tanh(l_1 \varepsilon_1), \dots, p_4 \tanh(l_4 \varepsilon_4))^T$, $p_i > 0$, $l_i > 0$ – положительные константы, $i = 1, \dots, 4$.

Устойчивость замкнутой системы наблюдения гарантируется следующей Леммой при наличии связи между гиперболическим тангенсом и логистической функцией $\tanh(k_i e_i) = \sigma(k_i e_i / 2)$, $\sigma(k_i e_i) = 2 / (1 + \exp(-k_i e_i)) - 1$ и при справедливости оценок (24).

Лемма 2. [25] Если $|F_{li}(\eta_1, \eta_2, t)| \leq \bar{F}_{li}$, $t \geq 0$, $i = 1, \dots, 4$ (12), то для любых $\Delta_{1i} > 0$, $\Delta_{2i} > 0$, $t_i^* > 0$ существуют такие значения $\underline{p}_i > 0$, $\underline{l}_i > 0$, что при любых $p_i > \underline{p}_i$, $l_i \geq \underline{l}_i$ выполняется $|\varepsilon(t)| \leq \Delta_{1i}$, $|\dot{\varepsilon}(t)| \leq \Delta_{2i}$, $t > t_i^*$, $i = 1, \dots, 4$.

Как следствие из Леммы 2, оценку неопределенностей с заданной точностью и за заданное время предоставляет корректирующее воздействие наблюдателя (38):

$$|v_i(t) - \tilde{F}_{li}(\eta_1, \eta_2, t)| \leq \Delta_{2i}, \quad t > t_i^*, \quad i = 1, \dots, 4. \quad (40)$$

С информационной поддержкой наблюдателя неопределенностей (38), (39) закон управления углами Эйлера и высотой (33) реализуется как:

$$\begin{aligned} e_1 &= \eta_1 - \eta_{1,\text{des}}(t), \quad e_2 = \eta_2 + M_1 \tanh(K_1 e_1), \\ u &= -B_0^{-1}(\bar{\eta})(F_0 + v + M_2 \tanh(K_2 e_2) + K_3 \ddot{\eta}_1) = -B_0^{-1}(\bar{\eta})(F_0 + v + \\ &+ M_2 \tanh(K_2(\eta_2 + M_1 \tanh(K_1(\eta_1 - \eta_{1,\text{des}}(t))))) + K_3 \ddot{\eta}_1). \end{aligned} \quad (41)$$

С учетом ошибки оценивания (40), используя (13), (24), из (34) можно получить следующую оценку точности в замкнутой системе с наблюдателем:

$$|e_{li}(t)| \leq \frac{H_{i,\text{des}} + \Delta_{2i}}{0.76^2 m_{li} m_{2i} k_{li} k_{2i}}, \quad t > t_{li}, \quad i = 1, \dots, 4.$$

В следующем разделе приводятся результаты натурных экспериментов.

6. Апробация алгоритмов управления. Апробация алгоритмов управления проходила на квадрокоптере со стандартной рамой F450 с конфигурацией «X» и с посадочными шасси [33] (рисунок 2).



Рис. 2. Квадрокоптер с рамой F450

Этот квадрокоптер был оснащен комплектом из четырех моторов T-Motor AIR2216 II KV920, четырех регуляторов угловых скоростей вращения моторов Electronic Speed Controller (ESC) T-Motor Air 20A и двух пар самозатягивающихся пропеллеров T-Motor T1045 II. Для питания использовался аккумулятор HRB Lipo 4S 14.8 V.

Для реализации системы управления на квадрокоптер был установлен полетный контроллер на базе микросхемы MDR32F9Q2I [34] (рисунок 3).




Рис. 3. Экспериментальный образец полетного контроллера на микросхеме MDR32F9Q2I

На борту полетного контроллера находились акселерометр и гироскоп MPU-6050, которые измеряли линейные ускорения и угловые скорости соответственно. Оценки углов Эйлера находились по этим измерениям с помощью фильтра Маджвика. Для измерения высоты использовался Venewake TFMini-Plus LiDAR. При этом оценки углов Эйлера и угловых скоростей поступали в систему управления с частотой 200 Гц, измерения высоты – с частотой 100 Гц.

В таблице 1 приведена информация о параметрах объекта управления.

Таблица 1. Информация о параметрах объекта управления

Описание параметра	Единица измерения	Номинальное значение
Момент инерции I_{01}	кг·м ²	0.0167
Момент инерции I_{02}	кг·м ²	0.0167
Момент инерции I_{03}	кг·м ²	0.0243
Масса m_0	кг	1.5
Длина плеча l (нормированная на $\sqrt{2}$)	м	0.16
Отношение коэффициента сопротивления формы к коэффициенту тяги c	м	0.0085

При этом номинальные значения моментов инерции и массы квадрокоптера были найдены автоматически с помощью построения 3D-модели объекта в Computer-aided design (CAD) системе.

Преобразование управлений в механической подсистеме – суммарной тяги u_z (Н) и моментов τ_p , τ_q , τ_r (Н·м) в ШИМ-сигналы происходило в два этапа. На первом этапе эти управления пересчитывались в силы тяги на каждом моторе T_i (Н) следующим образом:

$$\begin{pmatrix} T_1 \\ T_2 \\ T_3 \\ T_4 \end{pmatrix} = \frac{1}{4} \begin{pmatrix} -1 & -1/l & 1/l & 1/c \\ -1 & -1/l & -1/l & -1/c \\ -1 & 1/l & -1/l & 1/c \\ -1 & 1/l & 1/l & -1/c \end{pmatrix} \begin{pmatrix} u_z \\ \tau_p \\ \tau_q \\ \tau_r \end{pmatrix}. \quad (42)$$

Из (42) и таблицы 1 следует, что при расчете тяг на каждый мотор при управлении τ_p для крена и τ_q для тангажа находятся коэффициенты $1/l = 6.25$, при управлении τ_r для рыскания находится коэффициент $1/c = 117.65$. Таким образом, управление рысканием требует формирования моторами наибольших тяг по сравнению с каналами для других углов. Этот факт далее будет учтен при выборе коэффициентов регулятора (для рыскания они будут меньше, чем для крена и тангажа) так, чтобы не выйти за допустимые диапазоны изменения ШИМ-сигналов от 1150 до 2000 (мкс). При этом управление высотой осуществляется за счет суммарной тяги $u_z = T_1 + T_2 + T_3 + T_4$ на всех моторах, которая из физических ограничений не может превышать 53.76 (Н) по модулю.

Далее на втором этапе силы тяги (42) преобразовывались в ШИМ-сигналы $u_{\text{pwm}} = (u_{\text{pwm},1}, u_{\text{pwm},2}, u_{\text{pwm},3}, u_{\text{pwm},4})$ (мкс) с помощью следующей нелинейной зависимости, полученной экспериментально:

$$u_{\text{pwm},i} = \begin{cases} 1150, & 1000d_i + q_3 < 1150 \\ 1000d_i + q_3, & 1150 \leq 1000d_i + q_3 \leq 2000, \quad i = 1, \dots, 4, \\ 2000, & 1000d_i + q_3 > 2000 \end{cases} \quad (43)$$

где $d_i(U) = \frac{0.5}{q_1} \left(-q_2 + \sqrt{q_2^2 + \frac{4q_1 T_i}{1 + q_0(U-15)}} \right)$, значения вспомогательных

коэффициентов были следующими: $q_0 = 0.1026$, $q_1 = 13.1025$, $q_2 = 2.4655$, $q_3 = 1076.7019$; U – текущее напряжение. Для измерения этого напряжения на полетный контроллер также был установлен датчик CJMCU-219 на чипе INA219.

Далее ШИМ-сигналы (43) поступали на стандартные регуляторы ESC T-Motor Air 20A, которые осуществляли стабилизацию соответствующих угловых скоростей вращения моторов.

Код алгоритма управления и преобразования сил и моментов в ШИМ-сигналы был написан на C++. Он загружался в полетный контроллер с помощью интерфейсов Universal Serial Bus, Universal Asynchronous Receiver-Transmitter (USB-UART). В ходе полета задающие воздействия для углов Эйлера и высоты подавались на объект с помощью команд на ноутбуке и Raspberry PI. Кроме того, была предусмотрена возможность формировать задающие воздействия и передавать их на объект с помощью пульта управления FLYSKY FS-i6, приемника FSiA6B и системы Intelligent Input Bus (IBUS). Модули низкого уровня UART и Inter-Integrated Circuit (I2C) обеспечивали передачу информации (задающих воздействий для выходных переменных, измерений с датчиков) на микроконтроллер MDR32F9Q2I. Далее, на основе этих данных и кода алгоритма управления на C++ в микроконтроллере на низком уровне происходило формирование ШИМ-сигналов, и осуществлялась их передача на стандартные регуляторы скоростей вращения моторов ESC T-Motor Air 20A. Более подробное описание технических деталей представлено в [34], где также использовался микроконтроллер MDR32F9Q2I, но применительно к другому квадрокоптеру и с ПИД-регуляторами в качестве алгоритмов управления.

Ставилась задача стабилизации рыскания и высоты при их ступенчатом изменении, а также стабилизации нулевых значений крена и тангажа с величиной ошибки в установившемся режиме не более чем 2 (град) для углов Эйлера и не более чем 0.05 (м) для высоты. Допускалось, что неопределенности могут изменяться в следующих диапазонах:

$$|F_{1i}(t)| \leq 1146 \text{ (град / с}^2\text{)}, i = 1, 2, 3, |F_{14}(t)| \leq 8 \text{ (м/с}^2\text{)}, t \geq 0. \quad (44)$$

Из-за наличия перекрестных связей с рысканием (5) и с линейными скоростями [35] по каналам крена и тангажа действуют наибольшие по величине возмущения по сравнению с другими каналами, что далее будет учтено при выборе коэффициентов регулятора и наблюдателя неопределенностей.

На основе методов частотной идентификации [35] динамика моторов приближенно имитировалась подачей виртуальных управлений $u = (\tau_p, \tau_q, \tau_r, u_z)^T$ на фильтры нижних частот (ФНЧ):

$$\begin{aligned} 0.05\dot{\tilde{u}}_p &= -\tilde{u}_p + \tau_p, & 0.05\dot{\tilde{u}}_q &= -\tilde{u}_q + \tau_q, \\ 0.005\dot{\tilde{u}}_r &= -\tilde{u}_r + \tau_r, & 0.1\dot{\tilde{u}}_z &= -\tilde{u}_z + u_z, \end{aligned} \quad (45)$$

где $\tilde{u}_p$, $\tilde{u}_q$, $\tilde{u}_r$, $\tilde{u}_z$ – переменные состояния ФНЧ.

Из (45) следует, что наибольшие искажения виртуальных управлений за счет динамики моторов происходят в канале высоты, наименьшие – в канале рыскания. Чтобы уменьшить амплитуду паразитных низкочастотных гармоник, возникающих из-за искажения виртуальных управлений динамикой моторов (45), и уменьшить зашумленность сигналов, в замкнутую систему дополнительно были введены ФНЧ вида (45), которые применялись к сигналам e_{2i} с постоянными времени 0.0052 (для углов Эйлера), 0.01 (для высоты) и к сигналам корректирующих воздействий наблюдателя $v_i(t)$ с постоянными времени 0.05 (для углов Эйлера) и 0.28 (для высоты). Структурная схема замкнутой системы с учетом наблюдателя возмущений и ФНЧ, которая была апробирована на объекте, приведена на рисунке 4.

Значения коэффициентов регуляторов находились с опорой на достаточные условия устойчивости из Леммы 1 (процедура из раздела 3 не использовалась из-за более консервативных оценок в ней по сравнению с Леммой 1). Однако из-за консервативности нижних оценок на выбор амплитуд из доказательства Леммы 1 и ограничений на переменные состояния и управления, итоговые значения коэффициентов регуляторов были уменьшены относительно границ из Леммы 1 и найдены с помощью численного моделирования в MATLAB. Таким образом, для апробации алгоритмов управления были выбраны следующие значения коэффициентов.




Рис. 4. Структурная схема системы управления с наблюдателем возмущений и с фильтрами нижних частот

Для канала крена и тангажа:

$$m_{1i} = 4.8, k_{1i} = 1, m_{2i} = 10, k_{2i} = 4, k_{3i} = 2.25, i = 1, 2.$$

Для канала рыскания:

$$m_{13} = 0.4, k_{13} = 5, m_{23} = 0.5, k_{23} = 7, k_{33} = 0.$$

Для канала высоты:

$$m_{14} = 1.2, k_{14} = 0.6, m_{24} = 7, k_{24} = 0.75, k_{34} = 0.$$

Для рыскания было принято нулевое значение коэффициента усиления $k_{33} = 0$ при угловом ускорении, поскольку его управляющий момент наименее искажается динамикой моторов (45) по сравнению с другими каналами (напомним, что положительные значения коэффициентов при ускорениях позволяют уменьшить амплитуду колебаний, возникающих из-за динамики моторов). Хотя суммарная

тяга для управления высотой искажается динамикой моторов сильнее всего (45), для высоты также было принято $k_{34} = 0$. В этом случае так было сделано, чтобы не увеличивать зашумленность управления и не превышать допустимые ресурсы. Однако чтобы избежать сильных колебаний высоты из-за динамики моторов пришлось организовать в этом канале наиболее медленные переходные процессы по сравнению с остальными каналами. Таким образом, ненулевые коэффициенты усиления при ускорениях объекта были заданы только для крена и тангажа. Управление этими переменными требует меньше ресурсов, чем управление рысканием и высотой, при этом крен и тангаж также подвержены колебаниям из-за динамики моторов и конструктивных особенностей объекта.

Коэффициенты наблюдателя неопределенностей были приняты исходя из допустимых границ изменения неопределенностей (44) и исходя из обеспечения ошибки оценивания в установившемся режиме по модулю и не более чем 5 (град/с²) для углов Эйлера и не более чем 0.2 (м/с²) для высоты.

Для канала крена, тангажа и рыскания:

$$p_i = 30, l_i = 0.45, i = 1, 2, 3.$$

Для канала высоты:

$$p_4 = 15, l_4 = 0.34.$$

Предложенная модификация блочного подхода с сигмовидными обратными связями (БПС) сравнивалась со стандартным блочным подходом с линейными управлениями (БПЛ):

$$\begin{aligned} e_1 &= \eta_1 - \eta_{1,des}(t), \quad e_2 = \eta_2 + \hat{K}_1 e_1, \\ u &= -B_0^{-1}(\bar{\eta})(F_0 + z_2 + \hat{K}_2 e_2 + \hat{K}_3 \ddot{\eta}_1), \end{aligned} \quad (46)$$

где $z_2 \in R^{4 \times 1}$ – оценки неопределенностей, $\hat{K}_i = \text{diag}(\hat{k}_{i1}, \dots, \hat{k}_{i4})$ – диагональные матрицы, элементы которых являются константами (коэффициентами усиления), $i = 1, \dots, 4$.

При этом, как и для БПС, к сигналам e_{2i} для уменьшения зашумленности и уменьшения колебаний применялся ФНЧ с постоянными 0.0052 (для углов Эйлера) и 0.01 (для высоты).

Оценки z_2 неопределенностей для БПЛ предоставлял стандартный наблюдатель Луенбергера [36] с линейными корректирующими воздействиями:

$$\dot{z}_1 = z_2 + F_0 + B_0(\bar{\eta})u + L_1(e_2 - z_1), \quad \dot{z}_2 = L_2(e_2 - z_1), \quad (47)$$

где $z_1 \in R^{4 \times 1}$, z_2 – переменные состояния наблюдателя, $L_1 = \text{diag}(-2s_\phi, -2s_\theta, -2s_\psi, -2s_z)$, $L_2 = \text{diag}(s_\phi^2, s_\theta^2, s_\psi^2, s_z^2)$, $s_\phi, s_\theta, s_\psi, s_z$ – коэффициенты наблюдателя [36].

В отличие от БПС, к оценкам неопределенностей не применялись ФНЧ, чтобы для БПС и БПЛ использовались наблюдатели неопределенностей одного и того же суммарного порядка 8.

Были выбраны следующие коэффициенты регулятора в системе БПЛ с наблюдателем неопределенностей.

Для канала крена и тангажа:

$$\hat{k}_{1i} = 4.8, \quad \hat{k}_{2i} = 37, \quad \hat{k}_{3i} = 2.25, \quad i = 1, 2. \quad (48)$$

Для канала рыскания:

$$\hat{k}_{13} = 1.54, \quad \hat{k}_{23} = 2.6, \quad \hat{k}_{33} = 0. \quad (49)$$

Для канала высоты:

$$\hat{k}_{14} = 0.7, \quad \hat{k}_{24} = 0.75, \quad \hat{k}_{34} = 0. \quad (50)$$

Для объективности сравнения результатов апробации коэффициенты (48), (49) регулятора углов и наблюдателя для БПЛ были эмпирически подобраны на основе численного моделирования так, чтобы обеспечить примерно такое же время переходных процессов и такую же точность, как и в предложенной модификации блочного подхода с сигмовидными обратными связями БПС. Однако выбрать коэффициенты регулятора высоты для БПЛ, исходя из этой же цели, не удалось. Коэффициенты (50) приблизительно соответствовали предельным коэффициентам, при которых не возникает сильных колебаний по высоте. Было выявлено, что

увеличение коэффициентов относительно (50) приводит к увеличению амплитуды колебаний высоты и к риску возникновения аварийных ситуаций при использовании идентичных ФНЧ и наблюдателя того же порядка, что и в БПС. По этой причине достаточно маленькие коэффициенты (50) обеспечили более низкую точность стабилизации высоты по сравнению с БПС, но при меньших ресурсах управления (что будет продемонстрировано далее на графиках). Для возможности увеличения коэффициентов относительно (50) требовалось бы дополнительное решение по фильтрации в регуляторе БПЛ и/или повышение порядка наблюдателя неопределенностей.

Кроме того, для БПЛ приняты следующие коэффициенты наблюдателя Луенбергера (47):

$$s_{\phi} = -17, s_{\theta} = -17, s_{\psi} = -20, s_z = -4.5.$$

Таким образом, апробировались следующие алгоритмы управления и соответствующие замкнутые системы:

1. Блочный подход с сигмовидными управлениями (41) (БПС).

2. Блочный подход с линейными управлениями (46) (БПЛ).

В первом эксперименте по апробации алгоритмов управления требовалось, чтобы квадрокоптер поднялся на высоту -0.5 (м), затем отработал ступенчатое задающее воздействие для рыскания из 0 (град) в 10 (град) при стабилизации нулевых значений крена и тангажа.

На рисунке 5 приведены графики изменения рыскания $\psi(t)$ (град) и ступенчатого задающего воздействия $\psi_{\text{des}}(t)$ (град). Момент времени $t = 0$ (с) здесь и далее будет соответствовать времени подачи ступеньки. На рисунке 6 представлены графики управления $\tau_r(t)$ (Н·м). Для наглядности на этом рисунке также приведен график скачка управления при ступенчатом изменении задания, найденного путем вычитания из сигнала $\tau_r(t)$ его среднего значения за 0.5 (с) до подачи ступеньки (в результате этой операции $\tau_r(t)$ до подачи ступеньки становится примерно равным нулю, и далее можно объективно сравнить величины скачков для разных алгоритмов управления при небольших отличиях в начальных условиях, которые неизбежны из-за разной величины шумов и возмущений в разных экспериментах). На рисунках 7-8 приведены графики крена $\phi(t)$ и его управления $\tau_p(t)$ и тангажа $\theta(t)$ и его управления $\tau_q(t)$ соответственно. На рисунке 9

представлен график высоты $z(t)$ и ее управления $u_z(t)$. На рисунке 10 приведены графики линейных координат $x(t)$ и $y(t)$. На рисунке 11 приведены графики оценок неопределенностей с помощью корректирующего воздействия $v_3(t)$ предложенного наблюдателя (для БПС) и с помощью переменной $z_{23}(t)$ наблюдателя Луенбергера (для БПЛ), а также графики скачков оценок.




Рис. 5. Графики рыскания $\psi(t)$ и задающего воздействия $\psi_{des}(t)$







Рис. 6. Графики управления $\tau_r(t)$ и величины его скачка

Рис. 7. Графики крена $\phi(t)$ и управления $\tau_p(t)$ Рис. 8. Графики тангажа $\theta(t)$ и управления $\tau_q(t)$ Рис. 9. Графики высоты $z(t)$ и управления $u_z(t)$




 Рис. 10. Графики линейных координат $x(t)$ и $y(t)$


Рис. 11. Графики оценок неопределенности с помощью наблюдателей и величины их скачка

В таблице 2 приведены следующие количественные показатели качества работы наблюдателей неопределенностей: максимальное значение модуля оценки (град/с²).

В таблице 3 приведены следующие количественные показатели качества работы регуляторов: время переходного процесса, а именно: момент времени (с), начиная с которого ошибка слежения попадает в окрестность $|\psi(t) - 10| \leq 0.5$ (град) и более не покидает ее; максимальное значение модуля скачка управления (Н·м); среднее значение модуля ошибки слежения в установившемся режиме (град), средние значения модулей крена и тангажа (град) и максимальная ошибка стабилизации высоты на уровне -0.5 (м).

Таблица 2. Количественные показатели качества работы наблюдателей неопределенностей

Показатель	БПС	БПЛ
Максимальное значение модуля скачка оценки (град/с ²)	73.42	110.6

Таблица 3. Количественные показатели качества работы регуляторов

Показатель	БПС	БПЛ
Время переходного процесса (с)	2.35	1.94
Максимальное значение модуля скачка управления (Н м)	0.04041	0.05629
Среднее значение модуля ошибки слежения (град)	0.0638	0.0649
Среднее значение модуля крена (град)	0.0894	0.0709
Среднее значение модуля тангажа (град)	0.0875	0.0674
Максимальное значение ошибки стабилизации высоты (м)	0.027	0.038

Из рисунка 11 и таблицы 2 следует, что для БПС максимальный скачок оценочных сигналов неопределенностей оказался примерно в 1.51 раз меньше по сравнению с БПЛ за счет ограниченных сигмовидных корректирующих воздействий в предложенном наблюдателе по сравнению с линейными корректирующими воздействиями в наблюдателе Луенбергера [36].

Цель управления рысканием была достигнута для всех алгоритмов: время переходных процессов в этом случае составило примерно 2 (с) при средней величине ошибки в установившемся режиме не более чем 0.0649 (град) (рисунок 5, таблица 3). При этом для БПС максимальный скачок управления оказался в 1.39 раз меньше по сравнению с БПЛ (рисунок 6, таблица 3).

Отметим, что при обработке рысканием ступенчатого задающего воздействия крен и тангаж остаются в малой окрестности нуля (рисунок 7-8, таблица 3), что демонстрирует робастность всех алгоритмов управления к неопределенностям, возникающим из-за перекрестных связей. При этом использование линейных управлений уменьшало ошибки стабилизации крена и тангажа примерно до 1.3 раз по сравнению с использованием сигмовидных предположительно из-за меньшего влияния шумов измерений на линейные управления.

Из таблицы 3 также следует, что при обработке рысканием ступеньки максимальное отклонение высоты от задания -0.5 (м) по модулю составило 2.7 (см) для БПС, 3.8 (см) для БПЛ. Таким образом, для БПС ошибка оказалась в 1.41 раз меньше по сравнению с БПЛ.

Во втором и третьем экспериментах требовалось, чтобы рыскание и высота обрабатывали ступенчатые задающие воздействия с разной величиной скачков: для рыскания из -10 (град) в 0 (град)

(величина скачка 10 (град)) и из -15 (град) в 0 (град) (величина скачка 15 (град)) при стабилизации высоты на уровне -0.5 (м) и нулевых значений крена и тангажа; для высоты из -1 (м) в -0.5 (м) (величина скачка 0.5 (м)) и из -1.5 (м) в -0.5 (м) (величина скачка 1 (м)) при стабилизации нулевых значений углов Эйлера.

На рисунках 12-15 и в таблицах 4-5 приведены качественные и количественные показатели результатов апробации алгоритмов соответственно.




Рис. 12. Графики рыскания $\psi(t)$ и задающего воздействия $\psi_{des}(t)$




Рис. 13. Графики величины скачка управления $\tau_r(t)$




 Рис. 14. Графики высоты $z(t)$ и задающего воздействия $z_{des}(t)$

 Рис. 15. Графики величины скачка управления $u_z(t)$

 Таблица 4. Количественные показатели качества работы регуляторов
рыскания

Показатель	Скачок задания 10 (град)		Скачок задания 15 (град)	
	БПС	БПЛ	БПС	БПЛ
Максимальное значение модуля скачка управления (Н м)	0.0401	0.05408	0.04461	0.08594

Из таблицы 4 следует, что для БПС максимальный скачок управления меньше в 1.35 и 1.93 раза по сравнению с БПЛ при скачке задания по рысканию в 10 и 15 (град) соответственно. Следовательно, с увеличением скачка задающего воздействия для рыскания выигрыш

в уменьшении скачка управления возрастает для БПС относительно БПЛ.

Таблица 5. Количественные показатели качества работы регуляторов высоты

Показатель	Скачок задания 0.5 (м)		Скачок задания 1 (м)	
	БПС	БПЛ	БПС	БПЛ
Максимальное значение модуля скачка управления (Н)	3.488	1.336	4.961	3.08

Из таблицы 5 видно, что для БПЛ максимальный скачок управления меньше в 2.61 и 1.61 раза по сравнению с БПС при скачке задания по высоте в 0.5 и 1 (м) соответственно. В данном случае из-за достаточно малого скачка задания по высоте и из-за того, что коэффициенты в регуляторе высоты с линейными управлениями были меньше единицы, для БПЛ величина скачка управления оказалась меньше по сравнению с БПС. Однако с увеличением скачка задающего воздействия для высоты выигрыш в уменьшении скачка управления уменьшается для БПЛ относительно БПС.

Таким образом, результаты апробации показали эффективность предложенного алгоритма БПС. Исходя из результатов натурных экспериментов, можно сделать следующие выводы: если предполагается подавать на объект только гладкие задающие воздействия, либо негладкие с относительно небольшими скачками, и быстродействие отработки заданий не критично, то целесообразнее использовать линейные управления и БПЛ в виду простоты их реализации и их меньшей подверженности шумам измерений по сравнению с нелинейными управлениями. В противном случае (при негладких заданиях, когда важно быстродействие их отработки) рекомендуется использовать БПС для уменьшения скачков управления, уменьшения колебаний переменных состояния и увеличения точности в момент скачка задающего воздействия (по сравнению с БПЛ). При этом чем больше величина скачка задающих воздействий, тем выигрышнее будет применение БПС относительно БПЛ в плане качественных и количественных показателей качества регулирования.

7. Заключение. Цель работы состояла в разработке модификации блочного подхода для решения задач управления ориентацией и высотой квадрокоптера при наличии комплексных неопределенностей в модели объекта (внешних возмущений и параметрических неопределенностей, в том числе неучтенной

динамики). Цель была достигнута за счет разработки регулятора и наблюдателя неопределенностей с использованием сигмовидных обратных связей. В регуляторе и наблюдателе гладкие и ограниченные обратные связи позволили избежать большого перерегулирования, характерного для стандартного блочного подхода с линейными управлениями, а также уменьшить амплитуду управлений. Добавление слагаемых с ускорением объекта в регулятор обеспечило уменьшение колебаний переменных состояния, которые возникают из-за динамики моторов. Кроме того, за счет оценки неопределенностей с помощью корректирующих воздействий, предложенный наблюдатель с сигмовидными корректирующими воздействиями имеет меньший порядок по сравнению со стандартными наблюдателями (например, с наблюдателем Луенбергера). Результаты апробации алгоритмов на квадрокоптере со стандартной рамой F450 продемонстрировали их эффективность.

В будущем планируется разработать генератор задающих воздействий для сглаживания эталонных траекторий, которые имеют точки разрыва. Будет проведено исследование по разработке процедуры выбора значений коэффициентов регулятора с использованием менее консервативных оценок по сравнению с оценками из раздела 3 (так, чтобы выполнить заданные ограничения на переменные состояния и управления). Кроме того, планируется синтезировать регулятор линейными координатами x и y при наличии неопределенностей и провести апробацию алгоритмов.

Литература

1. Баранов О.В. Алгоритм настройки стабилизирующего ПИД-регулятора квадрокоптера // Известия высших учебных заведений: Приборостроение. 2021. Т. 64. № 10. С. 829–838.
2. Leal I.S., Abeykoon C., Perera, Y.S. Design, Simulation, Analysis and Optimization of PID and Fuzzy Based Control Systems for a Quadcopter // Electronics. 2021. vol. 10. no. 18. pp. 1–33.
3. Abdulkareem A., Oguntosin V., Popoola O.M., Idowu A.A. Modeling and Nonlinear Control of a Quadcopter for Stabilization and Trajectory Tracking // Journal of Engineering. 2022. vol. 2022. pp. 1–19.
4. Шмалько Е.Ю. Машинно синтезированное управление нелинейным динамическим объектом на основе оптимального расположения точек равновесия // Информатика и автоматизация. 2024. Т. 22. № 1. С. 87–109.
5. Барсегян В.Р., Симонян Т.А., Матевосян А.Г. Об одной задаче оптимального управления квадрокоптером с заданным промежуточным значением части координат фазового вектора // Дифференциальные уравнения и процессы управления. 2024. № 2. С. 59–72.
6. Ferede R., de Croon G., De Wagter C., Izzo D. End-to-end neural network based optimal quadcopter control // Robotics and Autonomous Systems. 2024. vol. 172. pp. 1–11.

7. Борисов О.И., Каканов М.А., Живицкий А.Ю., Пыркин А.А. Робастное траекторное управление квадрокоптером по выходу на основе геометрического подхода // Приборостроение. 2021. Т. 64. № 12. С. 982–992.
8. Nguyen N.P., Pitakwachara P. Integral terminal sliding mode fault tolerant control of quadcopter UAV systems // Sci Rep. 2024. vol. 14. pp. 1–16.
9. Rahmi E., Karaarslan A. Sliding Mode Control-Based Modeling and Simulation of a Quadcopter // Journal of Engineering Research and Reports. 2023. vol. 24. no. 3. pp. 32–41.
10. Яцун С.Ф., Емельянова О.В., Сантьяго Мартинез Леон А., Мигель Москера Морочо Л. Адаптивное управление нелинейным объектом типа конвертоплан в условиях неопределенностей // Известия Юго-Западного государственного университета. 2020. Т. 24. № 3. С. 35–50.
11. Глушенко А.И., Ласточкин К.А. Адаптивное управление с гарантией экспоненциальной устойчивости. Часть III. Объекты с переменными параметрами // Автоматика и телемеханика. 2023. № 11. С. 147–168.
12. Глушенко А.И., Ласточкин К.А. Адаптивный наблюдатель состояний и возмущений линейных систем с перепараметризацией // Автоматика и телемеханика. 2023. Т. 84. № 11. С. 115–146.
13. Xie W., Cabecinhas D., Cunha R., Silvestre C. Adaptive Backstepping Control of a Quadcopter With Uncertain Vehicle Mass, Moment of Inertia, and Disturbances // IEEE Transactions on Industrial Electronics. 2023. vol. 69. no. 1. pp. 549–559. DOI: 10.1109/TIE.2021.3055181.
14. Noordin A., Mohd Basri M.A., Mohamed Z. Real-Time Implementation of an Adaptive PID Controller for the Quadrotor MAV Embedded Flight Control System // Aerospace. 2023. vol. 10. no. 1. DOI: 10.3390/aerospace10010059.
15. Park D., Le T.-L., Quynh N.V., Long N.K., Hong S.K. Online Tuning of PID Controller Using a Multilayer Fuzzy Neural Network Design for Quadcopter Attitude Tracking Control // Frontiers in Neurorobotics. 2021. vol. 14. DOI: 10.3389/fnbot.2020.619350.
16. Ramírez-Neria M., Luviano-Juárez A., González-Sierra J., Ramírez-Juárez R., Aguerrebere J., Hernandez-Martinez E.G. Active Disturbance Rejection Control for the Trajectory Tracking of a Quadrotor // Actuators. 2024. vol. 13. no. 9. DOI: 10.3390/act13090340.
17. Khadraoui S., Fareh R., Baziyad M., Elbeltagy M., Bettayeb M. A Comprehensive Review and Applications of Active Disturbance Rejection Control for Unmanned Aerial Vehicles // IEEE Access. 2024. vol. 12. pp. 185851–185868.
18. Chang X., Jin C., Cheng Y. Dynamics and advanced active disturbance rejection control of tethered UAV // Applied Mathematical Modelling. 2024. vol. 135. pp. 640–665.
19. Буй В.Х., Маргун А.А., Бобцов А.А. Синтез наблюдателя переменных состояния и синусоидального возмущения для линейной нестационарной системы с неизвестными параметрами // Изв. вузов. Приборостроение. 2024. Т. 67. № 3. С. 209–219.
20. Андриевский Б.Р., Фуртат И.Б. Наблюдатели возмущений: методы и приложения. Часть 1. Методы // Автомат. и телемех. 2020. № 9. С. 3–61.
21. Sun H., Li J., Wang R., Yang K. Attitude Control of the Quadrotor UAV with Mismatched Disturbances Based on the Fractional-Order Sliding Mode and Backstepping Control Subject to Actuator Faults // Fractal Fract. 2023. vol. 7. no. 3. DOI: 10.3390/fractalfract7030227.
22. Smith S., Pan Y.-J. Adaptive Observer-Based Super-Twisting Sliding Mode Control for Low Altitude Quadcopter Grasping // IEEE/ASME Transactions on Mechatronics. 2025. vol. 30. no. 1. pp. 587–598.

23. Bingul Z., Gul K. Intelligent-PID with PD Feedforward Trajectory Tracking Control of an Autonomous Underwater Vehicle // *Machines*. 2023. vol. 11. no. 2. DOI: 10.3390/machines11020300.
24. Rao J., Li B., Zhang Z., Chen D., Giernacki W. Position Control of Quadrotor UAV Based on Cascade Fuzzy Neural Network // *Energies*. 2022. vol. 15. no. 5. DOI: 10.3390/en15051763.
25. Antipov A.S., Kokunko J.G., Krasnova S.A., Utkin V.A., Utkin A.V. Direct control of the endpoint of the manipulator under non-smooth uncertainty and reference trajectories // *Journal of the Franklin Institute*. 2023. vol. 360. no. 17. pp. 13430–13458.
26. Golubev A.E., Glazkov T.V. Nonlinear quadrotor control based on Simulink Support Package for Parrot Minidrones // *CEUR Workshop Proceedings*. 2020. vol. 2783. pp. 113–127.
27. Bici A., Minervini A., Godio S., Guglieri G., DAVIS F. Development and Validation of a LQR-Based Quadcopter Control Dynamics Simulation Model // *International Journal of Aerospace Engineering*. 2021. vol. 34. no. 6. DOI: 10.1061/(ASCE)AS.1943-5525.0001336.
28. Okasha M., Kraleev J., Islam M. Design and Experimental Comparison of PID, LQR and MPC Stabilizing Controllers for Parrot Mambo Mini-Drone // *Aerospace*. 2022. vol. 9. no. 6. DOI: 10.3390/aerospace9060298.
29. Ahn H., Hu M., Chung Y., You K. Sliding-Mode Control for Flight Stability of Quadrotor Drone Using Adaptive Super-Twisting Reaching Law // *Drones*. 2023. vol. 7. no. 8. DOI: 10.3390/drones7080522.
30. Krasnova S.A., Kokunko J.G., Kochetkov S.A., Utkin V.A. Generation of Achievable Three-Dimensional Trajectories for Autonomous Wheeled Vehicles via Tracking Differentiators // *Algorithms*. 2023. vol. 16. no. 9. DOI: 10.3390/a16090405.
31. Antipov A., Krasnova S., Utkin V. Methods of Ensuring Invariance with Respect to External Disturbances: Overview and New Advances // *Mathematics*. 2021. vol. 9. no. 23. DOI: 10.3390/math9233140.
32. Izadi M., Faieghi R. High-gain disturbance observer for robust trajectory tracking of quadrotors // *Control Engineering Practice*. 2024. vol. 145. DOI: 10.1016/j.conengprac.2024.105854.
33. Вольф Д.А., Широков А.С. Исследование основных и сопутствующих процессов управления полетом квадрокоптерной системы // *Труды 14-го Всероссийского совещания по проблемам управления (ВСПУ-2024, г. Москва, 17-20 июня 2024 г.)*. М.: ИПУ РАН, 2024. С. 1265–1269.
34. Wolf D., Alexandrov V., Shatov D., Rezkov I., Trefilov P., Meshcheryakov R. Development of a Firmware for Multirotor UAV Flight Controller Implemented on MCU MDR 32 // *Proceeding of the International Conference on Interactive Collaborative Robotics (ICR 2023)*. 2023. vol. 14214. pp. 345–356.
35. Alexandrov V., Rezkov I., Shatov D., Morozov Y. Frequency domain identification of the quadcopter attitude dynamics // *Advances in Systems Science and Applications*. 2023. vol. 23. no. 3. DOI: 10.25728/assa.2023.23.3.1424.
36. Herbst G. A Simulative Study on Active Disturbance Rejection Control (ADRC) as a Control Tool for Practitioners // *Electronics*. 2013. vol. 3(2). pp. 246–279.

Антипов Алексей Семенович — канд. техн. наук, старший научный сотрудник, лаборатория 37 «Систем с разрывными управлениями», ИПУ РАН. Область научных интересов: робастное управление (управление на скользящих режимах, блочный принцип управления), методы синтеза наблюдателей состояния и возмущений с применением алгоритмов к мехатронным системам. Число научных публикаций — 62.

scholess18@mail.ru; улица Профсоюзная, 65, 117997, Москва, Россия; р.т.: +7(495)198-1720,,1577.

Кокунько Юлия Георгиевна — научный сотрудник, лаборатория 37 «Систем с разрывными управлениями», ИПУ РАН. Область научных интересов: нелинейное робастное управление, блочный принцип управления с применением к системам слежения для беспилотных транспортных средств, функционирующих в условиях неопределенности и внешних возмущений, наблюдатели состояния и возмущений, синтез систем управления электромеханическими объектами и мобильными роботами. Число научных публикаций — 48. juliakokunko@gmail.com; улица Профсоюзная, 65, 117997, Москва, Россия; р.т.: +7(495)198-1720,,1577.

Вольф Данияр Александрович — канд. техн. наук, старший научный сотрудник, лаборатория 80 «Киберфизических систем», ИПУ РАН. Область научных интересов: исследование аппаратных и программных архитектур управления беспилотными летательными аппаратами, психоакустика. Число научных публикаций — 32. runsolar@mail.ru; улица Профсоюзная, 65, 117997, Москва, Россия; р.т.: +7(495)198-1720.

Широков Александр Сергеевич — младший научный сотрудник, лаборатория 80 «Киберфизических систем», ИПУ РАН. Область научных интересов: беспилотные летательные аппараты, мобильные роботы, системы управления роботами, применение групп роботов. Число научных публикаций — 22. shiras@ipu.ru; улица Профсоюзная, 65, 117997, Москва, Россия; р.т.: +7(495)198-1720,,1848.

Поддержка исследований. Работа выполнена при частичной финансовой поддержке РНФ (проект № 24-21-20009).

A. ANTIPOV, J. KOKUNKO, D. WOLF, A. SHIROKOV
**SYNTHESIS OF COMBINED QUADROCOPTER ATTITUDE
AND ALTITUDE CONTROL BASED ON BLOCK APPROACH
WITH SIGMOIDAL FEEDBACKS**

Antipov A., Kokunko J., Wolf D., Shirokov A. Synthesis of Combined Quadcopter Attitude and Altitude Control Based on Block Approach with Sigmoidal Feedbacks.

Abstract. This paper considers the problem of controlling the attitude and altitude of a quadcopter in the presence of uncertainties in the plant model. When solving this problem, it is especially important to consider the peculiarities of the plant: strong susceptibility to roll, pitch, and altitude oscillations due to the quadcopter design and motor dynamics (with yaw being the least susceptible to oscillations due to motor dynamics compared with other controllable variables). To achieve high control quality in the presence of uncertainties, combined control is usually applied. It is constructed as a sum of two parts: a basic stabilizing part and a part compensating uncertainties with the help of a disturbance observer. Typically, both parts contain linear feedback. However, when the output variables of the plant track non-smooth reference signals, linear feedback can cause overshooting and increased oscillations. To prevent these problems, we propose a combined control law with smooth and bounded feedback in the form of the hyperbolic tangent. This feedback is used by both the controller and the disturbance observer. In this case, the control synthesis is based on the structural properties of the plant using the block approach. Its application provided invariance of the output variables with respect to not only matched but also unmatched uncertainties, and also allowed to construct a disturbance observer of the minimum possible order. In addition, to reduce the oscillations, a part with plant accelerations was introduced into the control law. To realize the proposed approach, it is sufficient to know the nominal values of some parameters of the plant and the permissible bounds of uncertainty variation. We present the results of experiments on a quadcopter with an F450 frame and the results of a comparative analysis of the proposed approach with the one using linear control.

Keywords: UAV, external disturbances, combined control, block approach, hyperbolic tangent.

References

1. Baranov O.V. [Algorithm for tuning the stabilizing PID controller of quadcopter]. *Izvestija vysshih uchebnyh zavedenij: Priborostroenie*. – Proceedings of Higher Educational Institutions: Instrument engineering. 2021. vol. 64. no. 10. pp. 829–838. (In Russ).
2. Leal I.S., Abeykoon C., Perera, Y.S. Design, Simulation, Analysis and Optimization of PID and Fuzzy Based Control Systems for a Quadcopter. *Electronics*. 2021. vol. 10. no. 18. pp. 1–33.
3. Abdulkareem A., Oguntosin V., Popoola O.M., Idowu A.A. Modeling and Nonlinear Control of a Quadcopter for Stabilization and Trajectory Tracking. *Journal of Engineering*. 2022. vol. 2022. pp. 1–19.
4. Shmalko E.Ju. [Machine synthesized control of a nonlinear dynamic plant based on optimal arrangement of equilibrium points]. *Informatika i avtomatizacija – Informatics and automation*. 2024. vol. 22. no. 1. pp. 87–109. (In Russ).
5. Barsegjan V.R., Simonjan T.A., Matevosjan A.G. [On one problem of optimal control of a quadcopter with a given intermediate value of a part of phase vector

- coordinates]. *Differencial'nye uravnenija i processy upravlenija – Differential equations and control processes*. 2024. no. 2. pp. 59–72. (In Russ).
6. Ferede R., de Croon G., De Wagter C., Izzo D. End-to-end neural network based optimal quadcopter control. *Robotics and Autonomous Systems*. 2024. vol. 172. pp. 1–11.
7. Borisov O.I., Kakanov M.A., Zhivickij A.Ju., Pyrkin A.A. [Robust output trajectory control of quadcopter based on geometric approach]. *Priborostroenie. – Instrument engineering*. 2021. vol. 64. no. 12. pp. 982–992. (In Russ).
8. Nguyen N.P., Pitakwachara P. Integral terminal sliding mode fault tolerant control of quadcopter UAV systems. *Sci Rep*. 2024. vol. 14. pp. 1–16.
9. Rahmi E., Karaarslan A. Sliding Mode Control-Based Modeling and Simulation of a Quadcopter. *Journal of Engineering Research and Reports*. 2023. vol. 24. no. 3. pp. 32–41.
10. Jacun S.F., Emel'janova O.V., Santiago Martinez Leon A., Migel Mosquera Morochó L. [Adaptive control of a nonlinear plant of the convertoplane type under uncertainties]. *Izvestija Jugo-Zapadnog gosudarstvennogo universiteta – Proceedings of South-West State University*. 2020. vol. 24. no. 3. pp. 35–50. (In Russ).
11. Glushhenko A.I., Lastochkin K.A. Exponentially Stable Adaptive Control. Part III. Time-Varying Plants. *Avtomatika i telemekhanika – Automation and Remote Control*. 2023. vol. 84. no. 11. pp. 1232–1247. (In Russ).
12. Glushhenko A.I., Lastochkin K.A. Adaptive Observer of State and Disturbances for Linear Overparameterized Systems. *Avtomatika i telemekhanika – Automation and Remote Control*. 2023. vol. 84. no. 11. pp. 115–146. (In Russ).
13. Xie W., Cabecinhas D., Cunha R., Silvestre C. Adaptive Backstepping Control of a Quadcopter With Uncertain Vehicle Mass, Moment of Inertia, and Disturbances. *IEEE Transactions on Industrial Electronics*. 2023. vol. 69. no. 1. pp. 549–559. DOI: 10.1109/TIE.2021.3055181.
14. Noordin A., Mohd Basri M.A., Mohamed Z. Real-Time Implementation of an Adaptive PID Controller for the Quadrotor MAV Embedded Flight Control System. *Aerospace*. 2023. vol. 10. no. 1. DOI: 10.3390/aerospace10010059.
15. Park D., Le T.-L., Quynh N.V., Long N.K., Hong S.K. Online Tuning of PID Controller Using a Multilayer Fuzzy Neural Network Design for Quadcopter Attitude Tracking Control. *Frontiers in Neurobotics*. 2021. vol. 14. DOI: 10.3389/fnbot.2020.619350.
16. Ramírez-Neria M., Luviano-Juárez A., González-Sierra J., Ramírez-Juárez R., Aguerrebere J., Hernandez-Martinez E.G. Active Disturbance Rejection Control for the Trajectory Tracking of a Quadrotor. *Actuators*. 2024. vol. 13. no. 9. DOI: 10.3390/act13090340.
17. Khadraoui S., Fareh R., Baziyad M., Elbeltagy M., Bettayeb M. A Comprehensive Review and Applications of Active Disturbance Rejection Control for Unmanned Aerial Vehicles. *IEEE Access*. 2024. vol. 12. pp. 185851–185868.
18. Chang X., Jin C., Cheng Y. Dynamics and advanced active disturbance rejection control of tethered UAV. *Applied Mathematical Modelling*. 2024. vol. 135. pp. 640–665.
19. Buj V.H., Margun A.A., Bobcov A.A. [Synthesis of state variable observer and sinusoidal perturbation for linear nonstationary system with unknown parameters]. *Izvestija vysshih uchebnyh zavedenij: Priborostroenie. – Proceedings of Higher Educational Institutions: Instrument engineering*. 2024. vol. 67. no. 3. pp. 209–219. (In Russ).
20. Andrievskij B.R., Furtat I.B. Disturbance Observers: Methods and Applications. I. Methods. *Avtomatika i telemekhanika – Automate and remote control*. 2020. no. 9. pp. 3–61. (In Russ).

21. Sun H., Li, J., Wang, R., Yang K. Attitude Control of the Quadrotor UAV with Mismatched Disturbances Based on the Fractional-Order Sliding Mode and Backstepping Control Subject to Actuator Faults. *Fractal Fract.* 2023. vol. 7. no. 3. DOI: 10.3390/fractalfract7030227.
22. Smith S., Pan Y.-J. Adaptive Observer-Based Super-Twisting Sliding Mode Control for Low Altitude Quadcopter Grasping. *IEEE/ASME Transactions on Mechatronics.* 2025. vol. 30. no. 1. pp. 587–598.
23. Bingul Z., Gul K. Intelligent-PID with PD Feedforward Trajectory Tracking Control of an Autonomous Underwater Vehicle. *Machines.* 2023. vol. 11. no. 2. DOI: 10.3390/machines11020300.
24. Rao J., Li B., Zhang Z., Chen D., Giernacki W. Position Control of Quadrotor UAV Based on Cascade Fuzzy Neural Network. *Energies.* 2022. vol. 15. no. 5. DOI: 10.3390/en15051763.
25. Antipov A.S., Kokunko J.G., Krasnova S.A., Utkin V.A., Utkin A.V. Direct control of the endpoint of the manipulator under non-smooth uncertainty and reference trajectories. *Journal of the Franklin Institute.* 2023. vol. 360. no. 17. pp. 13430–13458.
26. Golubev A.E., Glazkov T.V. Nonlinear quadrotor control based on Simulink Support Package for Parrot Minidrones. *CEUR Workshop Proceedings.* 2020. vol. 2783. pp. 113–127.
27. Bici A., Minervini A., Godio S., Guglieri G., Dosis F. Development and Validation of a LQR-Based Quadcopter Control Dynamics Simulation Model. *International Journal of Aerospace Engineering.* 2021. vol. 34. no. 6. DOI: 10.1061/(ASCE)AS.1943-5525.0001336.
28. Okasha M., Kravlev J., Islam M. Design and Experimental Comparison of PID, LQR and MPC Stabilizing Controllers for Parrot Mambo Mini-Drone. *Aerospace.* 2022. vol. 9. no. 6. DOI: 10.3390/aerospace9060298.
29. Ahn H., Hu M., Chung Y., You K. Sliding-Mode Control for Flight Stability of Quadrotor Drone Using Adaptive Super-Twisting Reaching Law. *Drones.* 2023. vol. 7. no. 8. DOI: 10.3390/drones7080522.
30. Krasnova S.A., Kokunko J.G., Kochetkov S.A., Utkin V.A. Generation of Achievable Three-Dimensional Trajectories for Autonomous Wheeled Vehicles via Tracking Differentiators. *Algorithms.* 2023. vol. 16. no. 9. DOI: 10.3390/a16090405.
31. Antipov A., Krasnova S., Utkin V. Methods of Ensuring Invariance with Respect to External Disturbances: Overview and New Advances. *Mathematics.* 2021. vol. 9. no. 23. DOI: 10.3390/math9233140.
32. Izadi M., Faieghi R. High-gain disturbance observer for robust trajectory tracking of quadrotors. *Control Engineering Practice.* 2024. vol. 145. DOI: 10.1016/j.conengprac.2024.105854.
33. Volf D.A., Shirokov A.S. [Study of basic and related processes of flight control of quadcopter system]. *Trudy 14-go Vserossiyskogo soveshhanija po problemam upravlenija* [Proceedings of the 14th All-Russian Meeting on Control Problems]. Moscow: ICS RAS, 2024. pp. 1265–1269. (In Russ.).
34. Wolf D., Alexandrov V., Shatov D., Rezkov I., Trefilov P., Meshcheryakov R. Development of a Firmware for Multirotor UAV Flight Controller Implemented on MCU MDR 32. *Proceeding of the International Conference on Interactive Collaborative Robotics (ICR 2023).* 2023. vol. 14214. pp. 345–356.
35. Alexandrov V., Rezkov I., Shatov D., Morozov Y. Frequency domain identification of the quadcopter attitude dynamics. *Advances in Systems Science and Applications.* 2023. vol. 23. no. 3. DOI: 10.25728/assa.2023.23.3.1424.
36. Herbst G. A Simulative Study on Active Disturbance Rejection Control (ADRC) as a Control Tool for Practitioners. *Electronics.* 2013. vol. 3(2). pp. 246–279.

Antipov Aleksey — Ph.D., Senior researcher, Laboratory 37 «Systems with discontinuous controls», ICS RAS. Research interests: robust control (sliding mode control, block principle of control), methods of synthesis of state and disturbance observers with the application of algorithms to mechatronic systems. The number of publications — 62. scholess18@mail.ru; 65, Profsoyuznaya St., 117997, Moscow, Russia; office phone: +7(495)198-1720,,1577.

Kokunko Julia — Research associate, Laboratory 37 «Systems with discontinuous controls», ICS RAS. Research interests: nonlinear robust control, block control principle with application to tracking systems for unmanned vehicles operating under uncertainty and external disturbances, state and disturbance observers, synthesis of control systems for electromechanical plants and mobile robots. The number of publications — 48. juliakokunko@gmail.com; 65, Profsoyuznaya St., 117997, Moscow, Russia; office phone: +7(495)198-1720,,1577.

Wolf Daniyar — Ph.D., Senior researcher, Laboratory 80 “Cyberphysical systems”, ICS RAS. Research interests: research of hardware and software architectures for controlling unmanned aerial vehicles, psychoacoustics. The number of publications — 32. runsolar@mail.ru; 65, Profsoyuznaya St., 117997, Moscow, Russia; office phone: +7(495)198-1720.

Shirokov Aleksandr — Junior researcher, Laboratory 80 “Cyberphysical systems”, ICS RAS. Research interests: unmanned aerial vehicles, mobile robots, robot control systems, application of robot groups. The number of publications — 22. shiras@ipu.ru; 65, Profsoyuznaya St., 117997, Moscow, Russia; office phone: +7(495)198-1720,,1848.

Acknowledgements. This research is partially supported by the Russian Science Foundation (grant 24-21-20009).

А.С. РОДИОНОВ, Т.А. МАТКУРБАНОВ
**ПЛАНИРОВАНИЕ ТРАЕКТОРИИ ПОЛЕТА БПЛА
ПРИ МОНИТОРИНГЕ БОЛЬШОЙ ОБЛАСТИ**

Родионов А.С., Маткурбанов Т.А. Планирование траектории полета БПЛА при мониторинге большой области.

Аннотация. Современное сельское хозяйство охватывает огромные территории, и эффективный мониторинг этих территорий играет ключевую роль в точном земледелии. Беспроводные сенсорные сети широко используются для получения оперативной информации о состоянии сельскохозяйственных культур. Однако вручную собирать данные с датчиков затруднительно. В то же время беспилотные летательные аппараты (БПЛА) все чаще используются для обеспечения автоматического высокоточного сбора данных. В данной статье рассматриваются методы построения оптимальной траектории БПЛА, обеспечивающие эффективный сбор данных с распределенных сенсорных узлов. Предложенные методы направлены на минимизацию длины маршрута и полное покрытие зон датчиков за счет учета их пространственного распределения и радиуса действия. Целью исследования заключается оптимизация траектории полета БПЛА минимальной длины, обеспечивающей сбор данных со всех датчиков, полностью покрывая зоны покрытия сенсорных узлов. В рамках исследования были разработаны и сравнены четыре метода построения маршрута: центрированный, трехточечный, тангенциальный и метод оптимального выбора точек внутри границы радиуса. Каждый метод реализован в виде программного алгоритма, включающего этапы построения маршрута, его геометрической оптимизации и охвата зоны покрытия. Все методы были протестированы единообразно на наборе датчиков, размещенных на определенной территории. Оценка проводилась по трем основным показателям: протяженность маршрута, количество точек маневра и время расчета программы. Авторами предложены два ключевых метода оптимизации траектории: метод «центроид», основанный на кластеризационном подходе, и усовершенствованный «трехточечный» метод, реализующий алгоритм Лина–Кернигана. По результатам экспериментов предложенные методы существенно превосходят ранее рассмотренные методы планирования траектории. Таким образом, в статье предложен комплексный метод к построению маршрутов БПЛА для мониторинга сельскохозяйственных полей с учетом геометрических, алгоритмических и вычислительных факторов, а также даны рекомендации по выбору метода в зависимости от пространственной структуры сенсорной сети.

Ключевые слова: БПЛА, задача коммивояжера, алгоритм, кластеризации, Лина–Кернигана, Вельция, программирование.

1. Введение. Сельское хозяйство всегда рассматривалось как одна из важнейших человеческих инициатив в истории. В связи с быстрым распространением и развитием цифровизации сельского хозяйства, ключевые звенья сельскохозяйственного производства и биологического контроля все чаще опираются на передовые технологии. В частности, актуальной является технология сельскохозяйственной авиации, направленная на защиту растений [1].

В последнее время беспилотные летательные аппараты привлекли значительное внимание благодаря своей простоте, мобильности и маневренности. Кроме того, БПЛА могут поддерживать сбор данных в сельскохозяйственных приложениях, обеспечивая сбор информации через распределенные беспроводные устройства с устойчивостью к задержкам передачи данных [2].

Однако следует помнить, что беспилотный летательный аппарат является лишь инструментом для сбора данных. Он не может заменить агронома, но способен значительно повысить его эффективность, предоставляя актуальную информацию о состоянии сельскохозяйственных культур. Точная диагностика состояния почвы и растений позволяет как крупным, так и малым хозяйствам минимизировать потери, оперативно принимать необходимые меры и снижать затраты на рабочую силу. Специализированное программное обеспечение для мониторинга состояния полей собирает соответствующие данные и преобразует их в простые для анализа сведения, что облегчает процесс принятия решений [3].

С помощью беспилотных БПЛА агрономы могут быстро и относительно недорого получать данные о развитии растений на всех этапах – от посева до уборки урожая. Стремительное развитие беспилотных летательных аппаратов за короткий промежуток времени, а также совершенствование их управляемых полетных систем свидетельствует о том, что в будущем БПЛА станут неотъемлемой частью сельскохозяйственной авиации (рисунок 1).

В последнее время БПЛА были предложены в качестве мобильных узлов передачи данных для сбора информации из сети датчиков. По сравнению с традиционными наземными мобильными узлами передачи данных, такими как автомобили и роботы, способность БПЛА к полету позволяет им быстро перемещаться в непосредственную близость к устройствам, обходя препятствия на местности.

Наземные сенсорные устройства – это отдельный датчик (например, датчик температуры, влажности, освещённости и т.д.). Сенсорные сети представляют собой распределённую инфраструктуру, состоящую из автономных узлов, способных в реальном времени собирать, обрабатывать и передавать данные об окружающей среде. Сенсорный узел выполняет функции сбора информации, её первичной обработки и передачи по беспроводному каналу [4]. Основная особенность сенсорных сетей заключается в совмещении в узле приёмо-передатчика и измерительного датчика. Однако проектирование траектории полета БПЛА остается сложной задачей, поскольку оно

должно обеспечивать как энергоэффективность, так и минимальное время сбора данных.




Рис. 1. Иллюстрация движения беспилотного летательного аппарата над большими территориями

В данном исследовании основное внимание уделяется сенсорным сетям. В целом, если на больших сельскохозяйственных угодьях размещены датчики, то такую территорию можно рассматривать как сенсорную сеть [5 – 7].

Так как процесс сбора данных с датчиков, расположенных на больших территориях, тесно связан с траекторией полета БПЛА, для эффективного сбора информации требуется оптимизация траектории. Несмотря на существующие исследования в области управления движением БПЛА, многие из них не учитывают специфические требования к связи и задачам передачи данных. В связи с этим исследователи начали интегрировать управление движением с коммуникационными аспектами в системах БПЛА, что привело к разработке нескольких методов к проектированию траектории с целью оптимизации эффективности сбора данных.

Например, в работе [8] рассматривается не конкретное расположение отдельных сенсоров, а вся сенсорная область в целом. В данном методе интересующая зона разделяется на несколько подзон в соответствии с приоритетностью сбора данных. Оптимизированная

траектория формируется путем определения последовательности посещения этих подзон, при этом БПЛА должен собирать максимально возможное количество приоритетных данных в условиях ограниченной энергии. Однако в этом подходе не задаются конкретные координаты точек маршрута. В исследовании [9] предложен гибридный подход к сбору данных в крупных беспроводных сенсорных сетях (WSN) с использованием мобильных элементов и объединенной маршрутизационной схемы. Авторы сосредоточены на разработке многоэтапного маршрутизационного алгоритма и алгоритма формирования кластеров на основе плотности. В данном методе траектория определяется путем моделирования последовательности движения глав кластеров в рамках классической задачи коммивояжера. Однако для балансировки многозвенной маршрутизации и числа кластеров необходимо тщательно выбирать радиус кластера, причем конкретный метод его определения не был предложен.

В отличие от вышеупомянутого подхода к маршрутизации и кластеризации, в исследовании [10] предложена схема маршрутизации на основе минимального остовного дерева (MST) и алгоритм кластеризации, включающий метод К-средних для формирования кластеров примерно одинакового размера. В качестве решения для проектирования траектории, основанной на TSP, использовался алгоритм ближайшего соседа. Однако этот подход предполагает, что любые два датчика в WSN находятся в пределах радиусного диапазона связи друг с другом, что на практике не всегда осуществимо.

На рисунке 2 представлена начальная схема работы мобильного элемента D, который представляет собой беспилотный летательный аппарат, осуществляющий сбор данных в пределах радиуса покрытия сигнала БПЛА, состоящей из k датчиков, расположенных на большой территории.

Таким образом, разработка эффективного алгоритма для построения оптимальной траектории является одной из ключевых задач в области беспроводных сенсорных сетей и использования беспилотных летательных аппаратов.

Мы формулируем задачу оптимизации, решение которой позволяет определить траекторию БПЛА, максимизирующую количество собранных данных. В данном исследовании предлагаются два метода, которые обеспечивают приближенное решение задачи оптимизации траектории.




Рис. 2. Иллюстрация начального состояния движения беспилотного летательного аппарата в зоне покрытия

С постоянным развитием информационных технологий традиционные методы и инструменты планирования становятся менее эффективными для решения современных задач крупномасштабного планирования. В результате автономное планирование маршрутов постепенно становится неотъемлемой частью задачи планирования траектории БПЛА. В настоящее время для решения задачи автономного планирования траектории БПЛА предложено множество различных метаэвристических алгоритмов.

В работе [11, 12] предложенная схема формулируется как задача невыпуклой оптимизации, для решения которой применяется метод релаксации. В данной статье рассматривается сценарий, в котором сенсоры в беспроводной сети размещены в двух различных конфигурациях: пользователи, не обслуживаемые БПЛА, могут получать сигнал от базовой станции. Однако это приводит к увеличению затрат сети. Более того, если сенсоры не могут установить соединение с базовой станцией, БПЛА должен подлетать к ним и приближаться для передачи данных, что неизбежно приводит к удлинению траектории.

В исследовании [13] рассматривается задача полета БПЛА в пределах зоны покрытия базовой станции. Данный подход

накладывает ряд ограничений на траекторию полета, что может усложнить мониторинг больших сельскохозяйственных угодий. Более того, размещение базовых станций на обширных территориях требует значительных финансовых затрат, а может привести к проблемам с мониторингом этих устройств.

Несмотря на наличие ряда исследований в области маршрутизации БПЛА для сбора данных с беспроводных сенсорных сетей (БСС), большинство существующих решений ориентированы на упрощённые модели и не учитывают ключевые особенности аграрных сценариев [8 – 13]. Таким образом, существующие методы либо не учитывают важные геометрические и топологические характеристики сенсорных сетей, либо не адаптированы к условиям аграрных территорий. Это обуславливает необходимость разработки новых методов, учитывающих пространственное распределение сенсоров, радиус охвата и возможность геометрической оптимизации маршрута. Именно на решение этой задачи направлены предложенные в настоящем исследовании методы.

Таким образом, развитие технологий беспилотных летательных аппаратов и беспроводных сенсорных сетей требует разработки новых методов планирования траектории для эффективного сбора данных на больших территориях. В настоящем исследовании основное внимание уделяется построению оптимальных маршрутов БПЛА с использованием метаэвристических алгоритмов для решения задачи коммивояжера с окрестностями применительно к сельскохозяйственным сенсорным сетям.

2. Постановка задачи. В настоящей статье рассматривается задача построения оптимальной траектории полёта беспилотного летательного аппарата (БПЛА) с целью сбора данных с распределённых сенсорных узлов. Цель исследования заключается в разработке эффективных алгоритмов планирования маршрута, обеспечивающих полное покрытие сенсорной сети при минимально возможной длине траектории. Для достижения этой цели предложены два метода – кластеризация по центроиду и геометрически обоснованный трёхточечный алгоритм, каждый из которых реализован в виде программной модели и протестирован на одинаковых исходных данных.

Рассматривается поле большой площади, на котором размещены n сенсорных узлов. Каждый сенсор собирает данные об окружающей среде и сохраняет их во внутренней памяти. Однако, из-за ограниченной емкости памяти сенсоров, а также необходимости

оперативного анализа данных, информация должна периодически собираться с помощью беспилотного летательного аппарата.

Допустим, БПЛА предназначен для сбора данных, следуя определенной траектории, проходя через расположенные в поле сенсоры. При этом:

- начальная и конечная точка траектории совпадают, то есть БПЛА должен вернуться в исходное положение после завершения сбора данных;
- сенсорные узлы n расположены на определенных расстояниях друг от друга;
- БПЛА движется в плоскости x и y , и его маршрут должен быть рассчитан с учетом того, сколько точек он имеет на момент запуска.

Таким образом, маршрут БПЛА должен быть спроектирован так, чтобы он последовательно посещал все сенсоры и собирал данные. Приблизительное представление построения траектории можно увидеть на рисунке 3.




Рис. 3. Изображение траектории полета беспилотного летательного аппарата с определенным радиусом действия

Алгоритм нахождения кратчайшего пути основывается на разбиении сети на графовые компоненты и вычислении общей длины

маршрута на основе задачи коммивояжера. Должно минимизировать общее расстояние полёта и время соединения БПЛА с узлами.

На первом этапе маршрут БПЛА строится таким образом, чтобы минимизировать физическое расстояние между сенсорами. Сеть можно представить в виде графа

$$G = (K, E),$$

где: K – множество сенсоров, E – множество рёбер, соединяющих сенсоры.

Каждому ребру назначается вес, который соответствует расстоянию между двумя соединёнными сенсорами.

Для максимального увеличения времени работы БПЛА, предпочтительнее минимизировать суммарное расстояние между сенсорами в целевой области. Следовательно, задача разбиения графа для минимизации расстояний между сенсорами в сети формулируется следующим образом:

$$\min \sum_{(i,j) \in E} d(i,j),$$

где $d(i,j)$ – расстояние между сенсорами i и j .

Исследование [14] рассматривает оптимизацию траектории нескольких БПЛА с учетом возможных столкновений в сети FSO (Free-Space Optical). В этом исследовании графовая структура применяется для разделения пространства на области с минимальными задержками связи, что обеспечивает более эффективное планирование маршрутов.

Таким образом, использование разбиения сети на графовые компоненты и оптимизация маршрута на основе TSP позволяют значительно повысить эффективность работы БПЛА при мониторинге сельскохозяйственных угодий.

Задача минимизации общего пути беспилотного летательного аппарата формулируется следующим образом:

$$\min \sum_{(k,k') \in N} \|W_k - W_{k'}\|,$$

с учетом следующих условий:

$$K_1 \cup K_2 \cup \dots \cup K_m = K,$$

где: K – множество всех сенсоров, $K_1, K_2, \dots, K_m$ – разбиение множества сенсоров, W_k – координаты сенсора k , $W_{k'}$ – координаты следующего сенсора k' , $\|W_k - W_{k'}\|$ – евклидово расстояние между сенсорами k и k' .

Необходимо минимизировать суммарную длину маршрута, по которому БПЛА проходит через сенсоры, посещая каждый узел ровно один раз и возвращаясь в начальную точку. Данная задача широко известна как задача коммивояжера [15]. TSP является NP-трудной задачей, то есть поиск глобального оптимального решения требует значительных вычислительных ресурсов. Однако существуют эвристические и метаэвристические методы, позволяющие находить приближенные решения.

Решение задачи для БПЛА обладает рядом особенностей:

- БПЛА может лететь по прямой, т.е. расстояние между точками евклидово;
- беспилотный летательный аппарат имеет возможность снимать данные с сенсора, находясь в пределах радиуса радиовидимости.

Следует отметить, что в рамках проведённых моделирований и предложенных алгоритмов зоны, запрещённые для полётов (например, линии электропередач, высокие здания и иные препятствия), не учитывались. Внедрение таких ограничений может стать направлением дальнейших исследований.

Предлагается разбить задачу на ряд этапов:

- определение координат точек маршрута, учитывая первую особенность;
- нахождение приближённого решения задачи TSP одним из известных алгоритмов с учётом допустимой длины маршрута;
- корректировка маршрута с учётом возможности снятия данных с сенсоров «по дороге».

Максимальная зона действия сигнала беспилотного летательного аппарата определяется радиусом покрытия r . В начальном состоянии зона покрытия имеет форму круга, а ее площадь выражается формулой:

$$S_0 = \pi r^2.$$

При перемещении БПЛА на расстояние L его зона покрытия расширяется. Новая зона покрытия включает в себя как начальную область, так и дополнительную площадь, которая зависит от направления движения.

Общая площадь новой зоны покрытия определяется следующим выражением:

$$S = S_0 + S_{\text{доп}}.$$

Дополнительная зона покрытия формируется вследствие перемещения БПЛА. При этом границы охвата сигнала расширяются параллельно направлению движения. Основной компонент дополнительного покрытия определяется как:

$$S_{\text{доп}} = l * 2r.$$

То есть дополнительная площадь представляет собой прямоугольник, где: длина L – это пройденное расстояние БПЛА, ширина $2r$ – удвоенный радиус сигнала.

Таким образом, итоговая зона покрытия после перемещения БПЛА на расстояние L вычисляется как:

$$S = \pi r^2 + l * 2r.$$

Эта зависимость показывает, что дополнительное покрытие напрямую зависит от расстояния перемещения L и радиуса сигнала r .

Для математического описания движения БПЛА необходимо учитывать зависимость его координат от времени. Движение описывается в трехмерном пространстве с координатами (x, y, z) , где траектория выражается параметрическими уравнениями:

$$x = x(t), y = y(t), z = z(t),$$

где: t – время, $x(t)$, $y(t)$, $z(t)$ – координаты, изменяющиеся во времени.

Если радиус зоны покрытия сигнала БПЛА равен r , то в каждый момент времени зона покрытия представляет собой сферу с центром в точке $(x(t), y(t), z(t))$, что выражается уравнением:

$$(x - x(t))^2 + (y - y(t))^2 + (z - z(t))^2 = r^2.$$

Это уравнение описывает динамическую сферическую область покрытия вокруг БПЛА во время его полета.

Если БПЛА движется на постоянной высоте (то есть $z=h$ неизменно), то его координаты изменяются следующим образом:

$$x = vx(t) + x_0, y = vy(t) + y_0, z = h,$$

где: x_0, y_0 – начальные координаты БПЛА, vx, vy – проекции скорости движения на оси x и y .

В этом случае зона покрытия БПЛА во время движения в плоскости определяется уравнением:

$$(x - vx(t) - x_0)^2 + (y - vy(t) - y_0)^2 + (z - h)^2 = r^2.$$

Это уравнение описывает сферу, центр которой перемещается вдоль прямолинейной траектории в горизонтальной плоскости.

Чем больше мы увеличиваем радиус покрытия r беспилотного летательного аппарата, тем шире становится его зона охвата. Однако при этом возрастает и его энергопотребление. В то же время, длина траектории, сформированная для сбора данных с сенсоров в определенной области, уменьшается, то есть траектория становится короче.

При проектировании траектории полета БПЛА для задач сельскохозяйственного мониторинга необходимо учитывать ряд ключевых факторов. Основная проблема – необходимость построения маршрута, обеспечивающего покрытие всех сенсорных узлов в зоне действия сигнала при кратчайшей траектории.

Целью исследования является оптимизация траектории полета БПЛА минимальной длины, обеспечивающей сбор данных со всех датчиков, с полным покрытием зон покрытия всех сенсорных узлов.

Методы решения проблем. В статье предложены два метода решения проблемы и приведены экспериментальные сравнения.

Метод 1. Он основан на алгоритме кластеризации, называемом «центроид» [16]. Этот метод состоит из следующих этапов:

- цель состоит в том, чтобы сгруппировать точки датчиков, расположенные на определенном расстоянии, определить оптимальные центральные точки между ними и найти оптимальный путь, решив задачу коммивояжера;
- группировка близко расположенных точек выполняется на основе принципа кластеризации К-средних;
- для каждой группы рассчитывается средняя координата. Центральная точка будет средней координатой каждой группы;
- для каждой изолированной точки находится ближайшая центральная точка;
- ближайшая центральная точка определяется на основе евклидова расстояния;

- поиск кратчайшего пути для заданного набора точек;
- каждая точка посещается только 1 раз;
- последняя точка должна возвращаться к первой точке;
- эвристическое решение задачи TSP.

Метод 2. Метод, называемый трехточечным, основан на алгоритмах оптимизации [17, 18]. Этот метод состоит из следующих этапов:

- задача коммивояжера решается для соединения объектов, которые необходимо отслеживать БПЛА, с минимальным путем;
- кратчайший маршрут находится с помощью алгоритма Лина-Кернигана на основе дополнительных условий;
- БПЛА не обязательно должен проходить через центр каждого объекта наблюдения, а скорее входить в его зону покрытия (Зона покрытия – это географическая область, в пределах которой устройство или система способны функционировать, передавать или принимать сигнал);
- зоны мониторинга оптимизируются с использованием геометрических алгоритмов.

3. Системные модели. В исследовании системная модель понимается как совокупность следующих компонентов:

- графическая модель сенсорной сети, в которой сенсорные узлы представлены вершинами, а возможные соединения между ними представлены ребрами, взвешенными по расстоянию, т.е. Модель сенсорной сети в виде графа;
- модель движения БПЛА, учитывающая перемещение беспилотного аппарата в полете и радиус покрытия, описывающая зону сигнала в виде динамической окружности с определенным радиусом, т.е. Модель движения БПЛА с учётом радиуса покрытия;
- модель оптимизации маршрута, основанная на задаче коммивояжера, которая минимизирует общую длину пути БПЛА, охватывая все заданные точки или их зоны покрытия, т.е. Модель оптимизации маршрута на основе задачи коммивояжера.

Модель движения БПЛА с учётом радиуса покрытия.

БПЛА рассматривается как мобильный узел, имеющий динамическую зону покрытия радиусом r .

В каждый момент времени t его положение определяется координатами $(x(t), y(t))$. Зона покрытия описывается уравнением круга:

$$(x - x(t))^2 + (y - y(t))^2 = r^2.$$

При фиксированной высоте $z=h$ движение происходит в двумерной плоскости (х,у). Перемещаясь по траектории, БПЛА может считывать данные с сенсоров, находящихся в пределах зоны покрытия.

Модель оптимизации маршрута на основе задачи коммивояжера.

Построение оптимального маршрута сведено к задаче минимизации длины пути, проходящего через все целевые точки хотя бы один раз.

Целевая функция:

$$\text{Минимизировать } L = \sum_{i=0}^n (d(p_i, p_{i+1})),$$

где: p_i – индекс очередной посещаемой точки, $d(p_i, p_{i+1})$ – евклидово расстояние между двумя последовательными точками маршрута, $p_{i+1} = p_0$ – возвращение к начальной точке.

На основе этих моделей формализуется задача построения эффективной траектории полета БПЛА для сбора данных с распределенных сенсорных узлов. Для решения вышеуказанных проблем и задач мы используем несколько моделей.

Для вычисления центра и радиуса данной окружности применяется алгоритм Вельца (Welzl's Algorithm), который эффективно решает задачу минимального охватывающего круга [18 – 24].

Для трех заданных точек $A(x_A, y_A)$, $B(x_B, y_B)$ и $C(x_C, y_C)$, минимальная охватывающая окружность определяется следующим образом:

1. Определение вспомогательной переменной:

$$D = 2(A_x(B_y - C_y) + B_x(C_y - A_y) + C_x(A_y - B_y)).$$

2. Вычисление координат центра окружности:

$$U_x = \frac{(A_x^2 + A_y^2)(B_y - C_y) + (B_x^2 + B_y^2)(C_y - A_y) + (C_x^2 + C_y^2)(A_y - B_y)}{D},$$

$$U_y = \frac{(A_x^2 + A_y^2)(C_x - B_x) + (B_x^2 + B_y^2)(A_x - C_x) + (C_x^2 + C_y^2)(B_x - A_x)}{D}.$$

3. Определение радиуса окружности:

$$r = \sqrt{(U_x - A_x)^2 + (U_y - A_y)^2}.$$

Для оптимизации маршрута наблюдения беспилотного летательного аппарата используется классическая коммивояжерская задача. БПЛА должен облететь заданные объекты наблюдения, преодолев минимальное расстояние.

В задаче TSP коммивояжер должен посетить n городов, побывать в каждом только один раз и вернуться в исходную точку, минимизируя общую длину маршрута.

- n – количество точек для посещения.
- d_{ij} – расстояние между точками i и j .

$$\min \sum_{i=0}^n d(p_i, p_{i+1}) + d(p_n, p_1),$$

где: p_i – последовательность посещаемых точек.

Ограничение: каждая точка должна быть посещена только один раз, после чего необходимо вернуться в начальную точку.

Для расчета расстояний между точками применяется Евклидова метрика:

$$d(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}.$$

Для предварительного разбиения точек наблюдения используется алгоритм кластеризация К-средних, который разбивает множество данных на K кластеров. Этот метод позволяет минимизировать внутрикластерное расстояние и оптимизировать маршруты БПЛА.

- $X = \{x_1, x_2, \dots, x_n\}$ – множество данных из n точек.
- K – количество кластеров.
- $C = \{c_1, c_2, \dots, c_K\}$ – центры кластеров.

Каждая точка x_i относится к ближайшему центру кластера:

$$S_j = \{x_i \in X | d(x_i, c_j) \leq d(x_i, c_k) \forall k \neq j\},$$

где: S_j – множество точек, принадлежащих кластеру j , $d(x_i, c_j)$ – расстояние от точки x_i до центра кластера c_j .

Обновление центров кластеров:

$$c_i = \frac{1}{|S_j|} \sum_{x_i \in S_j} x_i,$$

где: c_i – новый центр кластера, S_j – количество точек в кластере j .

Функция оптимизации K-средних:

$$J = \sum_{j=1}^K \sum_{x_i \in S_j} d(x_i, c_i)^2.$$

Эта функция минимизирует внутри кластерное расстояние между точками и их центром.

Для привязки изолированных точек к ближайшим кластерам используется модель ближайшего соседа.

$$\arg \min d(i, j),$$

где: $j \in$ центральные точки кластеров.

Этот метод аналогичен алгоритму KNN (K-Nearest Neighbors) и использует Евклидово расстояние:

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^d (x_{ik} - x_{jk})^2}.$$

При выборе ближайшего кластера применяется правило голосования среди K ближайших соседей:

$$y' = \arg \max_c \sum_{i \in K} I(y_i = c),$$

где: y' – предполагаемый класс новой точки, $I(y_i = c)$ – индикаторная функция (1, если точка принадлежит классу c , 0 – иначе).

Таким образом, предложенные математические модели позволяют оптимизировать наблюдательный процесс БПЛА, обеспечивая минимальные энергозатраты, сокращение времени полета и улучшенное покрытие территории.

4. Рекомендуемое оптимизированное решение.

Рассматривается возможность создания беспилотного летательного аппарата, способного летать над несколькими географическими регионами и собирать данные из соответствующих точек. Каждая точка $i \in I$ представляет собой барицентр (центр массы) данного региона или определённую центральную «горячую точку». Координаты данной

точки на плоскости обозначим как x_i . БПЛА формирует траекторию, посещая определённые точки в заданной последовательности.

Учитывая радиационную диаграмму антенны, можно сделать вывод, что, когда БПЛА летит, область покрытия сигнала на поверхности Земли имеет форму окружности. Первая стратегия заключается в использовании метода, называемого «Центроид». Алгоритм, основанный на этом методе, приведен в листинге 1.

Входные данные: $P = \{p_1, p_2, \dots, p_n\}$ — множество точек.

Выходные данные: оптимальный маршрут M .

Шаг 1: Вычисление матрицы расстояний

for каждая пара $(p_i, p_j) \in P$:

$$D(i,j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

Шаг 2: Кластеризация и определение центральных точек

for каждая точка $p_i \in P$:

if p_i не принадлежит ни одной группе:

$G_i \leftarrow \{p_i\}$ // Создание новой группы

for каждая точка $p_j \in P$:

if p_j не используется и $D(i,j) \leq T$:

$G_i \leftarrow G_i \cup \{p_j\}$

Найти минимальную охватывающую окружность C_i для G_i

Шаг 3: Присоединение изолированных точек к ближайшему кластеру

for каждая изолированная точка $p_k \in P$:

$C_{\text{ближайший}} = \operatorname{argmin}_{\{C_i\}} D(p_k, C_i)$

p_k присоединяется к $C_{\text{ближайший}}$

Определить новую точку на расстоянии $T/2$ от p_k к $C_{\text{ближайший}}$

Шаг 4: Решение задачи коммивояжера

$M \leftarrow \{C_1, C_2, \dots, C_k\}$ — центры кластеров

$M \leftarrow$ Нахождение кратчайшего пути(M)

Шаг 5: Визуализация маршрута

Нарисовать найденный маршрут M

Добавить параллельные линии к маршруту на расстоянии g

Вывод: M — оптимальный маршрут.

Листинг 1. Алгоритм поиска оптимального маршрута на основе метода центроида

Вторая стратегия минимизации длины траектории БПЛА рассматривается с использованием метода названия «Трёх точек». Этот метод разработан для оптимизации маршрута с учётом радиуса покрытия связи и применением различных математических моделей и алгоритмов. Метод основывается на анализе точек покрытия, их геометрических характеристик и построении оптимального маршрута. В этом методе после первоначального построения маршрута применяется эвристика Лина-Кернигана. Этот метод позволяет

дополнительно сократить длину пути путём перестановки точек в маршруте. Сравниваются альтернативные пути, и выбирается наиболее короткий из возможных. Алгоритм, основанный на этом методе, приведен в листинге 2.

Входные данные:

$P = \{p_1, p_2, \dots, p_n\}$ – множество точек

r – радиус ограничения

Выход:

M – оптимальный маршрут

1. Вычисление матрицы расстояний:

for каждая пара $(p_i, p_j) \in P$:

$$D(i,j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

2. Решение задачи коммивояжёра:

$M \leftarrow \emptyset$

for каждая точка $p_i \in P$:

Найти оптимальное место вставки в маршрут

$M \leftarrow M \cup p_i$

$M \leftarrow M \cup p_0$

3. Геометрический анализ:

for каждый сегмент $(A, B, C) \in M$:

Вычислить прямую $y = mx + b$

Найти перпендикуляр

Вычислить расстояние от B до AC

if расстояние $< r$:

Переместить B в допустимую область

4. Удаление лишних точек:

for каждая точка $p_k \in P$:

if p_k находится в радиусе r от предыдущих E -точек:

Исключить p_k

5. Визуализация маршрута:

Отобразить точки и соединить их маршрутом

Нарисовать круги радиуса r вокруг каждой точки

Добавить параллельные линии к маршруту

Выход:

M – оптимальный маршрут

Листинг 2. Алгоритм поиска оптимального маршрута на основе трехточечного метода

5. Результаты. В этой статье представлены результаты моделирования для оценки эффективности алгоритмов поиска траектории полёта БПЛА при сборе данных от территориально распределённых источников (сенсоров). В частности, была построена оптимальная траектория для покрытия 100 точек, случайным образом размещённых в области размером 300×200 условных единиц, с

использованием четырёх различных алгоритмов. Следует отметить, что в четырёх методах координаты x и y выражены в абстрактных единицах. Для проведения симуляций использовалась облачная среда Google Colab с процессором Intel Xeon (на базе Google Compute Engine) и 12,67 ГБ оперативной памяти, что обеспечивало равные вычислительные условия при сравнении алгоритмов.

Представленная на рисунках 4, 5 и 6 демонстрирует результат работы алгоритма по 1-му методу, примененного к 100 случайно размещенным точкам. В ходе движения БПЛА он покрывает все точки, ориентируясь на заранее определенные контрольные точки и имея радиус покрытия r .

Согласно методу центроида, при заданном радиусе покрытия 10 условных единиц длина оптимального пути составляет 1611 условных единиц, а количество основных точек доступа для покрытия точек равно 60.




Рис. 4. Оптимальный вид покрытия всех точек при заданном радиусе покрытия 10 единиц по методу центроида

Согласно методу центроида, при радиусе покрытия 20 условных единиц оптимальная длина маршрута составляет 1398 единиц, а количество основных точек доступа для покрытия всех сенсорных точек – 33.




Рис. 5. Оптимальный вид покрытия всех точек при заданном радиусе покрытия 20 единиц по методу центроида

Согласно методу центроида, при радиусе покрытия 30 условных единиц оптимальная длина маршрута составляет 1089 единиц, а количество основных точек доступа для покрытия всех сенсорных точек – 20.




Рис. 6. Оптимальный вид покрытия всех точек при заданном радиусе покрытия 30 единиц по методу центроида

Рисунки 7-9 иллюстрируют результат работы алгоритма по 2-му методу. Аналогично, БПЛА движется в соответствии с радиусом покрытия r , охватывая все заданные контрольные точки.




Рис. 7. Оптимальное покрытие всех точек при заданном радиусе покрытия 10 условных единиц с использованием трехточечного метода




Рис. 8. Оптимальное покрытие всех точек при заданном радиусе покрытия 20 условных единиц с использованием трехточечного метода

Согласно трёхточечному методу, при радиусе покрытия 10 условных единиц оптимальная длина маршрута составляет 1622 единицы, а количество основных точек доступа для полного покрытия составляет 47.

Согласно трёхточечному методу, при радиусе покрытия 20 условных единиц оптимальная длина маршрута составляет 1324 единицы, а количество основных точек доступа, обеспечивающих полное покрытие, равно 21.




Рис. 9. Оптимальное покрытие всех точек при заданном радиусе покрытия 30 условных единиц, реализованное с использованием трёхточечного метода

Согласно трёхточечному методу, при радиусе покрытия 30 условных единиц оптимальная длина маршрута составляет 1161 единицу, а для полного покрытия всех точек требуется 17 ключевых точек доступа.

Предлагаемые методы были сопоставлены с рядом других методов. В частности, на основе тангенциальной стратегии, описанной в работе [25], был разработан усовершенствованный алгоритм с дополнительными этапами оптимизации, представленный в листинге 3. Для данного алгоритма была создана программная реализация, и проведено тестирование на тех же входных данных, которые использовались в экспериментах для двух ранее предложенных методов. Результаты тестирования представлены на рисунках 10-12.

Входные данные:

$P = \{p_1, p_2, \dots, p_n\}$ – множество точек

r – радиус ограничения

Выход:

M – минимальный маршрут UAV, охватывающий все зоны

1. Вычисление матрицы расстояний:

for каждая пара $(p_i, p_j) \in P$:

$$D(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

2. Построение предварительного маршрута (жадный алгоритм):

$M \leftarrow \{start\}$

while P не пусто:

 выбрать ближайшую точку

 добавить в маршрут

 удалить из непосещённых

Функция: `'greedy_order(points, start)'`.

3. Построение касательных точек:

for каждая пара $(p_i, p_{i+1}) \in M$:

 рассчитать угол между ними

 построить точку на границе радиуса r

Функция: `'tangent_point(center, target, r)'`.

4. Удаление лишних точек:

for каждый отрезок (a, b) маршрута:

 for каждая точка $c \in P$:

 if расстояние до $(a, b) \leq r$:

 считать покрытой

 удалить лишнюю точку из маршрута

Функция: `'distance_to_segment(p, a, b)'`.

5. Добавление недостающих касательных:

for каждая точка $c \in P$:

 if c не покрыта:

 построить касательную

 вставить перед концом маршрута

6. Расчёт длины маршрута

длина $\leftarrow$ сумма расстояний между последовательными точками маршрута

Листинг 3. Алгоритм поиска оптимального маршрута на основе тангенциального метода

Согласно тангенциальному методу, при радиусе покрытия 10 условных единиц оптимальная длина маршрута составляет 3342 единицы, а для полного покрытия всех точек требуется 55 ключевых точек доступа.




Рис. 10. Оптимальное покрытие всех сенсорных точек при радиусе охвата 10 условных единиц, реализованное с использованием тангенциального метода




Рис. 11. Оптимальное покрытие всех сенсорных точек при радиусе охвата 20 условных единиц, реализованное с использованием тангенциального метода

Согласно тангенциальному методу, при радиусе покрытия 10 условных единиц оптимальная длина маршрута составляет 2679 единиц, а для полного покрытия всех точек требуется 36 ключевых точек доступа.




Рис. 12. Оптимальное покрытие всех сенсорных точек при радиусе охвата 30 условных единиц, реализованное с использованием тангенциального метода

Согласно тангенциальному методу, при радиусе покрытия 30 условных единиц оптимальная длина маршрута составляет 2342 единицы, а для полного покрытия всех точек требуется 26 ключевых точек доступа.

Дополнительно был рассмотрен ещё один метод, описанный в работах [26 – 28], основанный на выборе оптимальной точки из множества точек, расположенных на расстоянии r от центра сенсорной зоны. На основе данного метода была реализована программная система с элементами оптимизации, алгоритм работы которой показан в листинге 4, и проведено тестирование аналогично предыдущим случаям. Результаты приведены на рисунках 13-15.

Процесс тестирования осуществлялся на том же процессоре и с теми же параметрами, что и в случае с вышеупомянутыми методами. Это позволило обеспечить сопоставимость условий и объективность сравнительного анализа.

Входные данные:

$P = \{p_1, p_2, \dots, p_n\}$ – множество центров сенсорных зон;

r – радиус зоны покрытия;

$start_point$ – начальная точка маршрута (обычно $(0, 0)$);

$samples_per_circle$ – количество пробных точек на границе каждой зоны.

1. Вычисление матрицы расстояний:

for каждая пара $(p_i, p_j) \in P$:

$$D(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$$

2. Масштабирование координат:

Для каждого центра $p_i = (x_i, y_i) \in P$:

$$p_i' = ((x_i - \min_x)/(\max_x - \min_x) * \text{ширина}, (y_i - \min_y)/(\max_y - \min_y) * \text{высота})$$

3. Генерация точек по окружности:

Для каждого центра $p_i \in P$:

Создать $samples_per_circle$ точек на окружности радиуса r вокруг p_i

4. Жадная вставка (optimal insertion):

Маршрут $\leftarrow [start_point]$

Пока остались незадействованные зоны:

Найти точку p среди всех зон, дающую минимальное увеличение длины маршрута

Вставить p в оптимальную позицию маршрута

Добавить $start_point$ в конец маршрута

5. Оптимизация маршрута с помощью 2-opt:

Повторять:

Находить пары сегментов маршрута, для которых инверсия уменьшает общую длину

Применять инверсию

Пока маршрут улучшается

6. Геометрическая фильтрация маршрута:

Для каждой тройки точек (A, B, C) в маршруте:

Если расстояние от центра зоны до отрезка $AB \leq r$ и B – точка из этой зоны:

Удалить B как лишнюю

7. Финальная 2-opt оптимизация:

Применить two_opt ко всему отфильтрованному маршруту

8. Проверка покрытия

Для каждой зоны p_i :

Если существует сегмент маршрута, расстояние от p_i до которого $\leq r$:

p_i считается покрытой

Листинг 4. Алгоритм поиска оптимального маршрута на основе выбора оптимальной точки

Согласно методу оптимального выбора, при радиусе покрытия 10 условных единиц оптимальная длина маршрута составляет 1885 единиц, а для полного покрытия всех точек требуется 82 ключевых точки доступа.




Рис. 13. Оптимальное покрытие всех точек датчика при условном радиусе покрытия 10 единиц, иллюстрация реализации с использованием метода оптимального выбора




Рис. 14. Оптимальное покрытие всех сенсорных точек при радиусе охвата 20 условных единиц, полученное с использованием метода оптимального выбора точек на границе зоны покрытия

Согласно методу оптимального выбора, при радиусе покрытия 20 условных единиц оптимальная длина маршрута составляет 1626 единиц, а для полного покрытия всех точек требуется 70 ключевых точки доступа.




Рис. 15. Оптимальное покрытие всех сенсорных точек при радиусе охвата 30 условных единиц, полученное с использованием метода оптимального выбора точек на границе зоны покрытия

Согласно методу оптимального выбора, при радиусе покрытия 30 условных единиц оптимальная длина маршрута составляет 1621 единиц, а для полного покрытия всех точек требуется 63 ключевых точки доступа.

При увеличении дальности радиопокрытия БПЛА расширяется зона охвата, что приводит к включению в сеть большего количества датчиков. Это изменение влияет на ключевые параметры системы: длину маршрута, количество точек маневрирования и время вычислений. Для количественного анализа данных зависимостей был проведен эксперимент с вариацией радиуса покрытия (рисунки 16-18).

Таким образом, пошаговое увеличение радиуса от минимального к максимальному значению позволяет получить полную картину влияния этого параметра на общую эффективность системы и служит основой для выбора оптимального радиуса в прикладных задачах мониторинга.




Рис. 16. График зависимости оптимального пути от радиуса покрытия, построенный на основе результатов моделирования алгоритмов, разработанных на основе каждого из четырех методов (центроидный метод показан синим цветом, трехточечный метод – оранжевым, тангенциальный метод – темным, а метод выборки – желтым)




Рис. 17. График зависимости времени расчета от радиуса покрытия программ, разработанных на основе четырех методов (центроидный метод показан синим цветом, трехточечный метод – оранжевым, тангенциальный метод – темным, а метод выборки – желтым)

На рисунке 16 представлена аналитическая зависимость оптимальной длины пути от радиуса, значения которого варьируются от 1 до 50 единиц для каждой реализации программного обеспечения, основанного на данном методе. Как видно из графика, увеличение радиуса приводит к уменьшению длины траектории.

На рисунке 17 представлен график зависимости величины радиуса от времени расчета программы в диапазоне от одной единицы до 50 единиц при тестировании программного обеспечения, созданного на основе каждого метода. Очевидно, что метод оптимального выбора дает плохие результаты по сравнению с другими методами.

На рисунке 18 показана зависимость количества горячих точек (зон интенсивного маневрирования), возникающих в заданной области, от радиуса покрытия, изменяющегося в диапазоне от 1 до 50 условных единиц. Данные получены в ходе тестирования программного обеспечения для каждого из рассматриваемых методов.




Рис. 18. График зависимости точек маневра от радиуса покрытия по результатам программ, разработанных на основе четырех методов (центроидный метод показан синим цветом, трехточечный метод – оранжевым, тангенциальный метод – темным, а метод выборки – желтым)

Сформирована таблица 1 усредненных аналитических результатов экспериментов, проведенных с использованием вышеуказанных методов.

Таблица 1. Сравнение методов друг с другом

Метод	Среднее время (с)	Средние манёвренные точки	Длина траектории (средняя)
Центроидный	0,05	~30	~1,300
Трёх точек	1,5	~25	~1,400
Тангенциальный	0.005	~35	~2,700
Оптимальный выбор	28,5	~65	~1,600

На основании приведенных выше графиков и таблицы 1 можно сделать вывод, что метод центроида является наиболее надежным и эффективным решением для повторяющихся вычислительных процессов, обеспечивая оптимальное сочетание скорости и стабильности. Этот метод показывает свои преимущества, особенно в системах реального времени или при обработке больших объемов данных.

Трёхточечный метод является оптимальным выбором, так как его среднее время выполнения составляет 1,5 секунды – это в 20 раз быстрее метода Оптимального выбора, при этом среднее количество финальных точек (25) на 17% точнее, чем у центроида, а средняя длина траектории (~1400) обеспечивает сбалансированную эффективность.

Из приведенных выше сравнительных графиков видно, что оптимальная длина траектории и покрытие точек доступа четырёх методов зависят от ширины сети в местах расположения указанных выше точек. Два предлагаемых нами метода имеют преимущества друг перед другом в некоторых аспектах. То есть, если рассматривать значение радиуса для 100 точек в указанной выше области, то трёхточечный метод неэффективен для значения радиуса до 21, но эффективен для радиуса покрытия больше 21. Если сравнивать по времени, то можно увидеть, что эффективен центроидный метод. Если сравнивать по горячим точкам, то можно считать эффективным трёхточечный метод.

В отличие от ранее применявшихся методов, основанных на методе выбора или тангенциальных точках, предложенные алгоритмы демонстрируют существенные преимущества. Центроидный метод обеспечивает минимальное время расчёта и сокращает длину маршрута за счёт кластеризации, а трёхточечный метод позволяет более точно учитывать геометрию покрытия и эффективно работать при больших радиусах. В целом, предложенные методы обеспечивают до 15-25% сокращения длины маршрута и до 30% уменьшения числа манёвровых точек при сопоставимом уровне охвата, что подтверждается результатами моделирования (рисунки 16-18).

Следует отметить, что радиус покрытия сигнала БПЛА является важным, но не единственным параметром при выборе оптимального метода планирования маршрута. При проектировании траектории следует учитывать такие факторы, как среднее расстояние между узлами датчиков, их пространственная плотность, а также возможные особенности размещения (кластеризация, изолированные узлы и т.д.). Без анализа конкретной пространственной структуры сенсорной сети выбор наиболее эффективного алгоритма может оказаться затруднительным или неверным. Поэтому для практического применения разработанных методов рекомендуется предварительно провести оценку распределения узлов и адаптировать выбор алгоритма в зависимости от особенностей исследуемой территории. Например, для густонаселенной сенсорной зоны метод центроида может оказаться эффективным.

6. Заключение. В данной статье рассматривается проблема оптимизации траектории беспилотного летательного аппарата (БПЛА) с учётом радиопокрытия для сбора данных с сенсорных узлов, распределенных по крупным сельскохозяйственным территориям. Были рассмотрены и реализованы четыре различных метода построения маршрута: центрированный, трехточечный, тангенциальный и метод оптимального выбора точек на окружности. Проведенное моделирование позволило оценить эффективность каждого метода по критериям длины маршрута, количества точек маневра и времени расчета для различных значений радиуса покрытия.

Эксперименты показали, что предложенные алгоритмы позволяют сократить длину маршрута на 15-25% и уменьшить количество манёвровых точек до 30% по сравнению с существующими подходами. Это подтверждается численными результатами (таблица 1) и графическим анализом (рисунки 16-18).

Полученные результаты показали, что разработанный авторами метод центроида отличается минимальным временем вычислений и высокой устойчивостью к изменению радиуса покрытия, в то время как метод трёх точек демонстрирует наибольшую эффективность при больших значениях радиуса. Тангенциальный метод, основанный на предыдущих разработках, показывает сбалансированную производительность при средних значениях радиуса, тогда как метод выбора оптимальной точки обеспечивает наибольшую гибкость и точность покрытия, особенно в условиях неоднородного распределения датчиков.

Таким образом, выбор подходящего алгоритма должен определяться конкретными условиями задач мониторинга: плотностью

размещения датчиков, энергетическими ограничениями, приемлемым временем полета, топологией исследуемой территории. Разработанные авторами на основе моделирования методы показали свое превосходство над ранее рассмотренными методами. Это поможет оптимизировать процесс сбора данных при использовании БПЛА на больших территориях.

В исследовании рассматривалась упрощенная плоская модель движения БПЛА без учета высоты полета. Влияние высоты на радиус покрытия, качество связи и энергопотребление пока не учитывалось и планируется для дальнейшего анализа. Также в рамках работы не рассматривались возможные сбои навигационной системы и необходимость динамической корректировки маршрута при отклонениях от траектории или потере связи. В будущем планируется разработать расширенные модели оптимизации 3D-траектории БПЛА с учетом энергетических затрат, качества сигнала, а также создание механизмов автоматического восстановления маршрута при возникновении непредвиденных ситуаций.

Литература

1. Tang Y., Fu Y., Guo Q., Huang H., Tan Z., Luo S. Numerical simulation of the spatial and temporal distributions of the downwash airflow and spray field of a co-axial eight-rotor plant protection UAV in hover. *Computers and Electronics in Agriculture*. 2023. vol. 206.
2. Raj M., Harshini N.B., Gupta S., Atiquzzaman M., Rawlley O., Goel L. Leveraging precision agriculture techniques using UAVs and emerging disruptive technologies // *Energy Nexus*. 2024.
3. Han Y. Application of Unmanned Aerial Vehicle Remote Sensing for Agricultural Monitoring // *E3S Web of Conferences*. EDP Sciences, 2024. vol. 553. DOI: 10.1051/e3sconf/202455302022.
4. Ногин А.А. Основные элементы структурной архитектуры сенсорных узлов // *Научный журнал*. 2018. № 5(28). С. 37–39.
5. Ghahramani M., Zhou M., Wang G. Urban sensing based on mobile phone data: Approaches, applications, and challenges. *IEEE/CAA J. Automat. Sinica*. 2020. vol. 7. no. 3. pp. 627–637.
6. Van Phan C., Park Y., Choi H.H., Cho J., Kim J.G. An energyefficient transmission strategy for wireless sensor networks. *IEEE Transactions on Consumer Electronics*. 2010. vol. 56. no. 2. pp. 597–605.
7. Han S., Zhu K., Zhou M., Liu X. Joint deployment optimization and flight trajectory planning for UAV assisted IoT data collection: A bilevel optimization approach. *IEEE Transactions on Intelligent Transportation Systems*. 2022. vol. 23(11). pp. 21492–21504.
8. Zhang B., Liu C.H., Tang J., Xu Z., Ma J., Wang W. Learning-Based Energy-Efficient Data Collection by Unmanned Vehicles in Smart Cities. *IEEE Transactions on Industrial Informatics*. 2018. vol. 14. no. 4. pp. 1666–1676.
9. Zhang R., Pan J., Xie D., Wang F. NDCMC: A Hybrid Data Collection Approach for Large-Scale WSNs Using Mobile Element and Hierarchical Clustering. *IEEE Internet of Things Journal*. 2015. vol. 3. no. 4. pp. 533–543.

10. Ebrahimi D., Sharafeddine S., Ho P.-H., Assi C. UAV-Aided Projection-Based Compressive Data Gathering in Wireless Sensor Networks. *IEEE Internet of Things Journal*. 2019. vol. 6. no. 2. pp. 1893–1905.
11. Li J., Zhao H., Wang H., Gu F., Wei J., Yin H., Ren, B. Joint optimization on trajectory, altitude, velocity, and link scheduling for minimum mission time in UAV-aided data collection. *IEEE Internet of Things Journal*. 2019. vol. 7(2). pp. 1464–1475.
12. Li G., Zhuang C., Wang Q., Li Y., Xu X., Zhou W. A UAV real-time trajectory optimized strategy for moving users. In *2019 11th International Conference on Wireless Communications and Signal Processing (WCSP)*. IEEE, 2019. pp. 1–6.
13. Bulut E., Guevenc I. Trajectory optimization for cellular-connected UAVs with disconnectivity constraint. *IEEE International Conference on Communications Workshops (ICC Workshops)*. IEEE. 2018. pp. 1–6.
14. Song S., Choi M., Ko D.E., Chung J.M. Multi-UAV trajectory optimization considering collisions in FSO communication networks. *IEEE Journal on Selected Areas in Communications*. 2021. vol. 39(11). pp. 3378–3394.
15. Davendra D. Traveling salesman problem: Theory and applications. *IntechOpen*, 2010. 338 p. DOI: 10.5772/547.
16. Гадасин Д.В., Золотарева П.Ю., Тремасова Л.А. Влияние кластеризации при обработке сырых данных // Системы синхронизации, формирования и обработки сигналов. 2024. № 3. С. 10–19.
17. Dasdan A. The Kernighan-Lin Search Algorithm // *arXiv preprint arXiv:2502.00316*. 2025. DOI: 10.48550/arXiv.2502.00316.
18. Марков А.В., Симаньков В.И. Методика расчета траекторий полета беспилотных летательных аппаратов для наблюдения за местностью // Доклады Белорусского государственного университета информатики и радиоэлектроники. 2019. № 4(122). С. 57–63.
19. Patra B., Bandyopadhyay S. Determination of the Minimum Enclosing Cone of a Finite Collection of Cones Sharing the Same Vertex // Available at SSRN 4801268. 2024. DOI: 10.2139/ssrn.4801268.
20. Flemming J. A simple linear time algorithm for smallest enclosing circles on the (hemi)sphere // *arXiv preprint arXiv:2407.19840*. 2024. DOI: 10.48550/arXiv.2407.19840.
21. Ци Ч. Исследование планирования траектории роторного БПЛА для распыления пестицидов // *StudNet*. 2021. Т. 4. № 7. С. 654–669.
22. Манакова В.А. Сравнительный анализ методов маршрутизации беспилотных авиационных систем для доставки груза // Системный анализ и логистика. 2023. № 4.
23. Rodionov A.S., Matkurbanov T.A., Yagibayeva M.R. Application of a Genetic Algorithm in Planning the Optimal Route of Unmanned Aerial Vehicles Used for Large Area Monitoring // *IEEE XVI International Scientific and Technical Conference Actual Problems of Electronic Instrument Engineering (APEIE)*. IEEE, 2023. pp. 1560–1564.
24. Родионов А.С., Маткурбанов Т.А., Хайруллаев У.Б. Оптимизация траектории полета БПЛА для мониторинга сельскохозяйственных земель // Проблемы информатики. 2025. № 1(66). С. 5–17. DOI: 10.24412/2073-0667-2025-1-5-17.
25. Stefan N., Plonski P.A., Isler V. Approximation algorithms for tours of orientation-varying view cones // *The International Journal of Robotics Research*. 2020. vol. 39. no. 4. pp. 389–401.
26. Jang D.-S., Chae H.-J., Choi H.-L. Optimal control-based UAV path planning with dynamically-constrained TSP with neighborhoods. *17th International Conference on*

- Control, Automation and Systems (ICCAS). IEEE, 2017. pp. 373–378. DOI: 10.23919/ICCAS.2017.8204468.
27. Boutselis G.I., Wang Z., Theodorou E.A. Constrained Sampling-based Trajectory Optimization using Stochastic Approximation. IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2020. pp. 2522–2528. DOI: 10.1109/ICRA40945.2020.9197284.
 28. Krishnan S., Nemati M., Loke S.W., Park J., Choi J. Energy-Efficient UAV-Assisted IoT Data Collection via TSP-Based Solution Space Reduction. GLOBECOM 2023 – 2023 IEEE Global Communications Conference. IEEE, 2023. pp. 6189–6194. DOI: 10.1109/GLOBECOM54140.2023.10437381.

Родионов Алексей Сергеевич — д-р техн. наук, доцент, заведующий лабораторией, лаборатория системного моделирования и оптимизации, Институт вычислительной математики и математической геофизики Сибирского отделения Российской академии наук (ИВМиМГ СО РАН); профессор кафедры, кафедра компьютерных систем, Новосибирский государственный университет (НГУ). Область научных интересов: математическое и имитационное моделирование систем сетевой структуры, анализ надёжности и живучести сложных систем. Число научных публикаций — 180. alrod@sscc.ru; проспект им. академика Лаврентьева, 6, 630090, Новосибирск, Россия; р.т.: +7(383)332-6949.

Маткурбанов Тулкин Алимбоевич — аспирант, кафедра компьютерных систем, Новосибирский государственный университет (НГУ). Область научных интересов: телекоммуникационные системы, системы слежения и управления движущимися объектами, сенсорные сети, управление проектами, программирование. t.matkurbanov@g.nsu.ru; улица Ляпунова, 4, 630090, Новосибирск, Россия; р.т.: +7(961)848-3662.

Поддержка исследований. Научное исследование выполнено при поддержке лаборатории системного моделирования и оптимизации Института вычислительной математики и математической геофизики Сибирского отделения Российской академии наук (ИВМиМГ СО РАН).

A. RODIONOV, T. MATKURBANOV
**PLANNING UAV FLIGHT TRAJECTORIES FOR MONITORING
LARGE AREAS**

Rodionov A., Matkurbanov T. Planning UAV Flight Trajectories for Monitoring Large Areas.

Abstract. Modern agriculture covers vast areas, and effective monitoring of these territories plays a key role in precision farming. Wireless sensor networks are widely used to obtain real-time information on the condition of agricultural crops. However, manually collecting data from such sensors (deployed across a sensor network) is challenging. At the same time, unmanned aerial vehicles (UAVs) are increasingly used to provide automated and highly accurate data collection. This article addresses the problem of constructing an optimal UAV trajectory to efficiently collect data from distributed sensor nodes. The goal is to minimize the total route length while fully covering the sensing zones of all devices. Within the study, four route planning methods were developed and compared: the centroid-based method, the three-point method, the tangential method, and the optimal point selection method within the coverage radius boundary. Each method was implemented as a programmatic algorithm, including route construction, geometric optimization, and coverage evaluation. All methods were tested under the same conditions using a set of sensors distributed over a defined area. Evaluation criteria included total path length, number of maneuver points, and computation time, across coverage radii from 1 to 50 meters. The authors propose two approaches for trajectory optimization: a clustering-based centroid algorithm and an enhanced three-point algorithm based on the Lin-Kernighan heuristic. Experimental results showed that the proposed dual-algorithm method significantly outperforms previously studied route planning methods. Thus, this paper presents a comprehensive approach to UAV route planning for agricultural field monitoring, considering geometric, algorithmic, and computational factors. It also provides practical recommendations for selecting the most suitable method based on the spatial structure of the sensor network.

Keywords: UAVs, traveling salesman problem (TSP), algorithm, clustering, Lin-Kernighan, Welzl's algorithm, programming.

References

1. Tang Y., Fu Y., Guo Q., Huang H., Tan Z., Luo S. Numerical simulation of the spatial and temporal distributions of the downwash airflow and spray field of a co-axial eight-rotor plant protection UAV in hover. *Computers and Electronics in Agriculture*. 2023. vol. 206.
2. Raj M., Harshini N.B., Gupta S., Atiquzzaman M., Rawley O., Goel L. Leveraging precision agriculture techniques using UAVs and emerging disruptive technologies. *Energy Nexus*. 2024.
3. Han Y. Application of Unmanned Aerial Vehicle Remote Sensing for Agricultural Monitoring. *E3S Web of Conferences*. EDP Sciences, 2024. vol. 553. DOI: 10.1051/e3sconf/202455302022.
4. Nogin A.A. [Basic elements of the structural architecture of sensor nodes]. *Nauchnyy zhurnal – Scientific Journal*. 2018. no. 5(28). pp. 37–39. (In Russ.).
5. Ghahramani M., Zhou M., Wang G. Urban sensing based on mobile phone data: Approaches, applications, and challenges. *IEEE/CAA J. Automat. Sinica*. 2020. vol. 7. no. 3. pp. 627–637.

6. Van Phan C., Park Y., Choi H.H., Cho J., Kim J.G. An energyefficient transmission strategy for wireless sensor networks. *IEEE Transactions on Consumer Electronics*. 2010. vol. 56. no. 2. pp. 597–605.
7. Han S., Zhu K., Zhou M., Liu X. Joint deployment optimization and flight trajectory planning for UAV assisted IoT data collection: A bilevel optimization approach. *IEEE Transactions on Intelligent Transportation Systems*. 2022. vol. 23(11). pp. 21492–21504.
8. Zhang B., Liu C.H., Tang J., Xu Z., Ma J., Wang W. Learning-Based Energy-Efficient Data Collection by Unmanned Vehicles in Smart Cities. *IEEE Transactions on Industrial Informatics*. 2018. vol. 14. no. 4. pp. 1666–1676.
9. Zhang R., Pan J., Xie D., Wang F. NDCMC: A Hybrid Data Collection Approach for Large-Scale WSNs Using Mobile Element and Hierarchical Clustering. *IEEE Internet of Things Journal*. 2015. vol. 3. no. 4. pp. 533–543.
10. Ebrahimi D., Sharafeddine S., Ho P.-H., Assi C. UAV-Aided Projection-Based Compressive Data Gathering in Wireless Sensor Networks. *IEEE Internet of Things Journal*. 2019. vol. 6. no. 2. pp. 1893–1905.
11. Li J., Zhao H., Wang H., Gu F., Wei J., Yin H., Ren, B. Joint optimization on trajectory, altitude, velocity, and link scheduling for minimum mission time in UAV-aided data collection. *IEEE Internet of Things Journal*. 2019. vol. 7(2). pp. 1464–1475.
12. Li G., Zhuang C., Wang Q., Li Y., Xu X., Zhou W. A UAV real-time trajectory optimized strategy for moving users. In *2019 11th International Conference on Wireless Communications and Signal Processing (WCSP)*. IEEE, 2019. pp. 1–6.
13. Bulut E., Guevenc I. Trajectory optimization for cellular-connected UAVs with disconnectivity constraint. *IEEE International Conference on Communications Workshops (ICC Workshops)*. IEEE. 2018. pp. 1–6.
14. Song S., Choi M., Ko D.E., Chung J.M. Multi-UAV trajectory optimization considering collisions in FSO communication networks. *IEEE Journal on Selected Areas in Communications*. 2021. vol. 39(11). pp. 3378–3394.
15. Davendra D. Traveling salesman problem: Theory and applications. *IntechOpen*, 2010. 338 p. DOI: 10.5772/547.
16. Gadasin D.V., Zolotareva P.Yu., Tremasova L.A. [The effect of clustering in raw data processing]. *Sistemy sinhronizacii, formirovaniya i obrabotki signalov – Systems of Synchronization, Signal Formation and Processing*. 2024. no. 3. pp. 10–19. (In Russ.).
17. Dasdan A. The Kernighan-Lin Search Algorithm. *arXiv preprint arXiv:2502.00316*. 2025. DOI: 10.48550/arXiv.2502.00316.
18. Markov A.V., Simankov V.I. [A methodology for calculating UAV flight trajectories for area observation]. *Doklady Belorusskogo gosudarstvennogo universiteta informatiki i radioelektroniki – Reports of the Belarusian State University of Informatics and Radioelectronics*. 2019. no. 4(122). pp. 57–63. (In Russ.).
19. Patra B., Bandyopadhyay S. Determination of the Minimum Enclosing Cone of a Finite Collection of Cones Sharing the Same Vertex. Available at SSRN 4801268. 2024. DOI: 10.2139/ssrn.4801268.
20. Flemming J. A simple linear time algorithm for smallest enclosing circles on the (hemi)sphere. *arXiv preprint arXiv:2407.19840*. 2024. DOI: 10.48550/arXiv.2407.19840.
21. Qi, Ch. [Research on rotor UAV trajectory planning for pesticide spraying]. *StudNet*. 2021. vol. 4. no. 7. pp. 654–669. (In Russ.).
22. Manakova V.A. [Comparative analysis of routing methods for unmanned aerial systems used for cargo delivery]. *Sistemnyj analiz i logistika – Systems Analysis and Logistics*. 2023. no. 4. (In Russ.).

23. Rodionov A.S., Matkurbanov T.A., Yagibayeva M.R. Application of a Genetic Algorithm in Planning the Optimal Route of Unmanned Aerial Vehicles Used for Large Area Monitoring. IEEE XVI International Scientific and Technical Conference Actual Problems of Electronic Instrument Engineering (APEIE). IEEE, 2023. pp. 1560–1564.
24. Rodionov A.S., Matkurbanov T.A., Khairullaev U.B. [UAV flight trajectory optimization for agricultural land monitoring]. Problemy informatiki – Informatics Issues. 2025. no. 1(66). pp. 5–17. DOI: 10.24412/2073-0667-2025-1-5-17. (In Russ.).
25. Stefas N., Plonski P.A., Isler V. Approximation algorithms for tours of orientation-varying view cones. The International Journal of Robotics Research. 2020. vol. 39. no. 4. pp. 389–401.
26. Jang D.-S., Chae H.-J., Choi H.-L. Optimal control-based UAV path planning with dynamically-constrained TSP with neighborhoods. 17th International Conference on Control, Automation and Systems (ICCAS). IEEE, 2017. pp. 373–378. DOI: 10.23919/ICCAS.2017.8204468.
27. Boutselis G.I., Wang Z., Theodorou E.A. Constrained Sampling-based Trajectory Optimization using Stochastic Approximation. IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2020. pp. 2522–2528. DOI: 10.1109/ICRA40945.2020.9197284.
28. Krishnan S., Nemati M., Loke S.W., Park J., Choi J. Energy-Efficient UAV-Assisted IoT Data Collection via TSP-Based Solution Space Reduction. GLOBECOM 2023 – 2023 IEEE Global Communications Conference. IEEE, 2023. pp. 6189–6194. DOI: 10.1109/GLOBECOM54140.2023.10437381.

Rodionov Alexey — Ph.D., Dr.Sci., Associate Professor, Head of the laboratory, Laboratory of system modeling and optimization, Institute of Computational Mathematics and Mathematical Geophysics of the Siberian Branch of the Russian Academy of Sciences (ICM&MG SB RAS); Professor of the department, Computer systems department, Novosibirsk State University (NSU). Research interests: mathematical and simulation modeling of network structure systems, analysis of reliability and survivability of complex systems. The number of publications — 180. alrod@sscc.ru; 6, Lavrentyev Av., 630090, Novosibirsk, Russia; office phone: +7(383)332-6949.

Matkurbanov Tulkın — Ph.d. student, Computer systems department, Novosibirsk State University (NSU). Research interests: telecommunication systems, tracking and control of moving objects, sensor networks, project management, programming. t.matkurbanov@g.nsu.ru; 4, Lyapunova St., 630090, Novosibirsk, Russia; office phone: +7(961)848-3662.

Acknowledgements. The scientific research was supported by the Laboratory of System Modeling and Optimization of the Institute of Computational Mathematics and Mathematical Geophysics of the Siberian Branch of the Russian Academy of Sciences.

S. PAWALE, P. PATIL

A COMPREHENSIVE ANALYSIS OF MULTI-CHANNEL MAC AND CLUSTERING PROTOCOLS FOR ROBUST AND ENERGY-EFFICIENT WIRELESS SENSOR NETWORKS

Pawale S., Patil P. A Comprehensive Analysis of Multi-Channel Mac and Clustering Protocols for Robust and Energy-Efficient Wireless Sensor Networks.

Abstract. Wireless Sensor Networks have become indispensable in various applications, from environmental monitoring to health tracking. As they continue to evolve, security and energy efficiency remain paramount. This analysis paper compares contemporary techniques within two significant protocol categories: Multi-Channel Medium Access Control (MAC) protocols and Cluster-Based protocols. The evaluation focuses on various channel assignment strategies and clustering methods, including static and dynamic allocation of communication resources, adaptive methodologies, and hybrid approaches, alongside strategies for selecting and rotating cluster heads, and aggregating data efficiently. Through a comprehensive examination, we highlight the limitations and potential of each approach, proposing a hybrid framework that leverages the strengths of both protocol types to enhance security and energy efficiency in Wireless Sensor Networks. Our findings suggest that integrating dynamic resource allocation with energy-efficient clustering and adaptive strategies with rotational cluster head selection could lead to more robust and efficient deployments. This analysis serves as a foundational study for future research, aiming to develop advanced hybrid protocols that address the dynamic demands of WSNs, ensuring sustainable and efficient network operations.

Keywords: Wireless Sensor Networks (WSNs), Multi-Channel Medium Access Control (MAC) protocols, Cluster-Based protocols, security, energy efficiency.

1. Introduction. WSNs detect ambient factors such as heat, light, sound, pressure, vibration, and electromagnetic fields over a specific area of interest [1]. These networks are made up of a large number of sensor nodes, each of which has sensors, wireless communication devices, processing units, and batteries [2]. WSNs have been a study topic since their inception, with multiple applications in a variety of industries. WSNs were created for military use, but have now expanded to encompass healthcare, habitat monitoring, environmental monitoring, traffic control, home automation, disaster relief, and smart cities. Sensor nodes are placed throughout an area to detect certain occurrences, which are then reported to a base station. Base stations act as intermediaries between end users and sensor nodes, offering more communication resources, processing power, and energy than sensor nodes [3, 4].

Power consumption limits on sensor nodes have a substantial impact on a sensor network's lifetime [5, 6]. Sensor nodes often have restricted power sources and use energy for data sensing, processing, and communication [7]. Wireless sensor networks (WSNs) now have communication and routing protocols. The network lifespan is an important metric for evaluating WSN

performance [8]. Direct connection between sensor nodes and base stations is the most important component in energy consumption, as sensor nodes far from a base station can quickly empty their batteries and fail [9]. To overcome this issue, clustered transmission techniques have been proposed. In these protocols, WSNs are organized into clusters, with cluster heads collecting and relaying sensed data to base stations. This minimizes energy consumption in these nodes by shortening the effective communication distance. Cluster heads collect data before sending it to the base station. Providing an energy-efficient protocol immediately increases network lifetime, making green communication a necessity for humans. There are several approaches to cluster creation and cluster head selection, however, using an energy-efficient methodology directly boosts network longevity [10]. Table 1 provides a clear comparison of how these techniques address common challenges in WSNs through their unique methods while sharing overarching goals such as improving network performance, enhancing security, optimizing energy efficiency, supporting scalability, and addressing interference and congestion.

This analysis paper aims to address the critical issues of security and energy efficiency in WSNs. Through an in-depth evaluation of existing protocols and strategies, it highlights the potential improvements and innovations necessary for advancing WSN technology. The key contributions of this research are:

- This research provides a comprehensive review and comparative analysis of Multi-Channel MAC and Cluster-Based protocols, focusing on their impact on security, energy efficiency, and scalability in Wireless Sensor Networks (WSNs).
- It systematically identifies key strengths of both protocols, such as interference mitigation and congestion control in Multi-Channel MAC and resource optimization with localized data aggregation in Cluster-Based approaches. Additionally, it highlights limitations, including synchronization overhead in Multi-Channel MAC and cluster head bottlenecks in Cluster-Based protocols.
- Based on the analysis, the study proposes a hybrid framework that integrates the adaptive channel allocation of Multi-Channel MAC with the hierarchical clustering mechanisms of Cluster-Based protocols. This integration enhances spectral efficiency, optimizes energy consumption, and reduces control overhead.
- The hybrid approach also incorporates dynamic trust-based security mechanisms, protecting the network from jamming, eavesdropping, and malicious node intrusions, thereby ensuring a more resilient and secure communication infrastructure.

– The findings of this research establish a foundation for the development of next-generation WSN protocols, offering a scalable, energy-efficient, and adaptive solution tailored for applications in IoT-based smart environments, industrial automation, and mission-critical sensing networks.

Table 1. Comparison of various energy-efficient communication protocols in WSN

Criteria	Multi-Channel MAC Protocols	Channel Hopping Techniques	Cluster-Based Protocols	Multi-Path Routing Protocols
Improving Network Performance	Reduces congestion and interference by using multiple channels.	Avoids interference and eavesdropping, ensuring reliable communication.	Organizes nodes into clusters to reduce overhead and improve resource management.	Ensures continuous communication through multiple paths, enhancing reliability.
Enhancing Security	Spreads communication over multiple channels to prevent jamming and interception.	Frequently changes channels to prevent attackers from predicting communication patterns.	Incorporates trust and authentication mechanisms within clusters.	Uses multiple paths to detect and isolate malicious nodes, mitigating attacks.
Optimizing Energy Efficiency	Minimizes collisions and retransmissions, conserving battery power.	Avoids congested channels, reducing the need for energy-consuming retransmissions.	Localizes communication within clusters, reducing energy for long-distance transmissions.	Balances load across multiple paths, preventing overuse of any single node and extending network lifetime.
Scalability and Flexibility	Efficiently manages multiple channels, supporting larger networks.	Dynamically adapts to network conditions, enhancing robustness.	Organizes network into manageable clusters, simplifying resource allocation.	Provides multiple routing options, handling increased traffic and node density.
Addressing Interference and Congestion	Distributes communication over several channels to mitigate interference.	Frequently changes channels to avoid interference based on predefined sequences.	Limits intra-cluster communication, aggregating data at cluster heads before sending it to the base station.	Distributes traffic across multiple paths, preventing congestion on any single path and improving data throughput.

The structure of this document is organized to provide a comprehensive analysis and evaluation of current protocols in WSNs and propose innovative solutions. Section 1 introduces the critical issues of

security and energy efficiency in WSNs and outlines the objectives of this study. Section 2 presents a detailed literature survey, reviewing existing protocols, and highlighting their strengths and limitations. Section 3 describes the methods used for the analysis, including the evaluation criteria and the comparative discussion of different strategies. Section 4 presents the results of the analysis and offers a comparative study, proposing a hybrid framework that integrates the most effective aspects of both protocol types. Finally, Section 5 concludes the document, summarizing the key findings and contributions of the research, and suggesting directions for future work in developing advanced protocols for WSNs.

2. Literature Survey. Recent research focuses on topics such as data collection, routing, WSN denoising, and grouping. Low-power WSN routing techniques are being developed to prevent duplicate transmission [11]. However, bandwidth use and network congestion may arise. Large wireless sensor networks frequently use restricted batteries, making rapid recharge challenging. An effective fuzzy logic method tackles energy efficiency concerns and proposes a congestion control-based optimal routing solution for wireless sensor networks [12].

The GWO approach selects a node (Ch) based on its energy balance, enabling the creation of homogeneous networks [13]. This strategy, paired with other characteristics, saves energy and keeps nodes from leaving the network. To address the denoising issue, the Denoising Autoencoder (DAE) employs data reconstruction and measurement matrices using earlier sensing data. This approach prevents nodes from leaving the network prematurely, saving wasteful energy consumption [14].

Fuzzy logic algorithms are critical for choosing channels in sensor-enabled IoT environments [15]. The CH node selection approach, which considers density, centrality, and energy level, differs from the traditional LEACH method. The base station uses a Mamdani fuzzy inference algorithm to choose CH nodes for data analysis. CHEF proposed a novel CH selection approach that considers local distance and residual energy characteristics [16].

The Taylor family's multi-hop routing system uses GWO to determine the ideal number of hops, with data transmission taking place via intermediary nodes in each cluster [17]. The system also uses SVRDO-SIDNL (Shift Invariant Deep Neural Learning) and supports vector Regression Dragonfly optimization to reduce latency and enhance data transfer [18].

A PSO-based coverage control system has been proposed, determining the detection radius of wireless sensor networks based on the energy usage area of each grid [19]. An energy-efficient trajectory

scheduling method has been developed to extend the life of wireless sensor networks [20].

Paper [21] proposed the Developed Distributed Energy-Efficient Clustering (DDEEC) for heterogeneous wireless sensor networks, but they did not consider distance factors when picking cluster managers. This approach is comparable to study [22] proposal, which incorporated super nodes to increase network longevity but did not account for the distance between nodes and the base station when picking cluster heads.

In paper [23] the authors have explained TDEEC. The technique used three tiers of nodes and a modified probability function. The space between nodes was not considered when calculating the heads. Paper [24] introduced EDDEEC for Wireless Sensor Networks. The protocol combines E-DEEC and DDEEC protocols, although it does not handle head selection based on distance from the BS. This challenge is similar to that proposed by the authors in paper [25], which described the Improved iDDEEC method. It changed the average chance of progressed nodes having residual energy less than the threshold value. However, no consideration was given to the distance between the nodes and the base station. Paper [26] also suggested a heterogeneous version of the Modified Low Energy Adaptive Clustering Hierarchy called Servant-MODLEACH. The method uses three types of nodes: advanced, servant, and normal. The protocol selects CHs based on their residual energy, disregarding the distance between the nodes and the BS. In study [27] the authors described an upgraded version of the TDEEC.

The new method, which employs a gateway in the center of the sensing area and a base station located far from the sensing field, does not take distance into account when selecting cluster heads. Paper [28] proposed the Stable Election Protocol (SEP) for heterogeneous wireless sensor networks, which uses each node's weighted election probability as a criterion to select a cluster leader based on their energy. SEP employs two types of nodes: normal and advanced, with normal nodes using the least energy. Simulation studies suggest that the SEP protocol enhances the network's lifetime.

This study seeks to address the security and energy efficiency issues confronting WSNs in a variety of applications, including environmental monitoring and healthcare. By analyzing current protocols, it identifies areas for improvement and suggests hybrid techniques to overcome these constraints. The study is critical for building resilient, secure, and energy-efficient protocols that can match the changing demands of WSNs, hence increasing their applicability and endurance in real-world applications. The research is critical for guaranteeing reliable and long-term network operations in WSNs.

3. Analysis of Routing Protocol. This analysis paper delves into the various MAC protocols, focusing on their channel assignment strategies and clustering mechanisms. It explores different approaches to channel assignment for multiplexing protocols, including Static Frequency Assignment in FDMA, TDMA, CDMA, and other strategies like SDMA, OFDMA, NOMA, and Hybrid Multiplexing. The paper further examines random access protocols, discussing Individual and Random Assignment, Static Uniform Distribution, and Load-Balanced Assignment. For token passing protocols, it evaluates strategies such as Multiple Rings with Uniform Distribution, Single Rings with Multiple Tokens, and Load-Balanced Rings. Additionally, the paper addresses cluster-based protocols, detailing Cluster Formation Strategies including Distance-Based, Energy-Based, and Hybrid Clustering. It also investigates Cluster Head Selection Strategies such as Random, Weighted, and Rotational Selection, and concludes with a review of Data Aggregation Strategies, encompassing Simple, Hierarchical, and Adaptive Aggregation. This comprehensive analysis provides insights into the efficiency and adaptability of various MAC protocols in managing multiple channels and optimizing network performance.

3.1. MAC Protocols. Wireless communication systems, particularly WSNs, require efficient MAC protocols to manage collisions and increase network performance [29]. Traditional MAC protocols include multiplexing, random access, and token passing [30]. However, the full potential of MAC [31] protocols in leveraging multiple frequency and space channels remains unexplored [32] due to the need for a larger number of channels for scalable frequency/space multiplexing and a lack of comprehensive studies on multi-channel random access variants [33, 34].

3.1.1. Channel Assignment Strategies for Multiplexing Protocols. Multiplexing protocols can be implemented using various techniques such as FDMA [35], TDMA [36], and CDMA [37] and similar others. We will examine three specific channel assignment strategies for these multiplexing techniques. FDMA is simple to implement, as it ensures that each node has a specific frequency range, preventing clashes. However, it lacks flexibility and may result in inefficient channel utilization if traffic loads are unevenly distributed between nodes [38]. TDMA increases flexibility by modifying time slot allocations in response to network traffic conditions. It gives equal access to the communication medium and can greatly reduce collisions. However, it necessitates accurate synchronization and may complicate handling dynamic time slots [39]. CDMA is highly flexible and scalable, allowing for several continuous broadcasts without tight time or frequency limits. It is very efficient at handling variable traffic loads and can improve

overall network performance. The key problem is the complexity of coordinating code assignments while guaranteeing minimal interference [40]. Spatial Division Multiple Access (SDMA) has the potential to greatly enhance network capacity while simultaneously reducing interference. It necessitates sophisticated antenna systems and exact spatial information regarding node positions. It is extremely effective in situations with well-distributed nodes but may be less useful in heavily populated places [41]. Orthogonal Frequency Division Multiple Access (OFDMA) can support high data speeds and is resistant to multipath fading. It provides flexibility in allocating sub-carriers based on node requirements and can adjust to changing traffic loads. However, extensive signal processing and subcarrier control are required [42]. Non-Orthogonal Multiple Access (NOMA) can greatly improve spectral efficiency while accommodating a large number of users. It is appropriate for cases with fluctuating channel conditions and user needs. The complexity resides in the design of efficient encoding and decoding algorithms, as well as interference management [43]. Hybrid Multiplexing such as F-TDMA, combines multiplexing technologies to improve efficiency and flexibility, reduce collisions, and maximize channel utilization. Implementing these tactics is complex and necessitates sophisticated coordinating systems [44].

3.1.2. Channel Assignment Strategies for Random Access Protocols. The BRS protocol has nodes competing for channel access, with nodes resuming when the channel is busy or collisions occur [45 – 48]. Three channel assignment options were investigated to increase performance.

Individual and Random Assignment provides simplicity and randomization while reducing predictable patterns that could be exploited (Figure 1). However, it may not be appropriate for high-load cases with frequent channel conflict [49].




Fig. 1. Individual and Random Assignment for Random Access Protocols

Static Uniform Distribution does not adapt well to spatially uneven traffic, potentially resulting in underutilized lanes and more collisions in high-traffic locations [50] (Figure 2).




Fig. 2. Static Uniform Distribution for Random Access Protocols

Load-balanced assignment considers the projected traffic load to optimize channel utilization and minimize collisions (Figure 3). It is more sophisticated, but it may be more effective in dynamic and high-load applications [51].




Fig. 3. Load-balanced assignment for Random Access Protocols

3.1.3. Channel Assignment Strategies for Token Passing Protocols.

Token passing systems group nodes into a virtual ring and pass tokens consecutively to control access [52, 53]. In a multi-channel setup with NC channels, each channel can function as a token, presenting alternative design strategies. Multiple Rings with Uniform Distribution simplify implementation, but it may not be efficient in dealing with varying load distributions, perhaps resulting in unequal ring utilization [54, 55]. A Single Ring with Multiple Tokens improves token circulation flexibility and may alleviate delays caused by high-load nodes. However, it may add complexity to controlling token hops and ensuring equal access [56, 57]. Load-Balanced Rings optimize load distribution, which may improve performance under a variety of traffic circumstances. It requires more effort to install, but it can considerably improve network efficiency and reliability [58, 59].

Channel assignment schemes for multiplexing, random access, and token passing offer distinct trade-offs in terms of simplicity, adaptability, and performance. While AS1 techniques are simple, they may not perform well in dynamic or high-load conditions. Some solutions are more complicated and offer better load balancing, which improves network performance and dependability in stressful situations. Effective Multi-Channel MAC protocols are critical for improving the performance of WSNs, particularly in contexts with shared communication channels. Future research should focus on creating scalable and adaptable multi-channel MAC protocols that can dynamically react to changing network conditions.

3.2. Cluster-Based Protocols. Cluster-based routing methods are important in Wireless Sensor Networks (WSNs) because they group nodes to improve resource management, energy efficiency, and data transmission. These methods improve network scalability and reliability by localizing data transfer inside clusters and lowering communication overhead [60 – 63]. In this section, we will look at several cluster formations, cluster head selection, and data aggregation procedures and assess their merits and shortcomings.

3.2.1. Cluster Formation Strategies. Cluster formation in WSNs improves network performance, resource management, and energy efficiency by grouping nodes into clusters. This approach decreases communication overhead while increasing scalability by handling smaller groups of nodes. It optimizes energy consumption, enables effective data aggregation and routing, and helps to improve load distribution, fault tolerance, and network lifetime. Common clustering tactics include.

Distance-based clustering is straightforward and intuitive, and it minimizes intra-cluster communication energy usage. However, this may result in unequal cluster sizes and unbalanced energy usage among clusters [64]. Energy-based clustering balances energy usage across the network, extending its lifetime. It necessitates frequent energy level updates, which might raise communication overhead for energy status interchange [65]. Hybrid Clustering blends the advantages of closeness and energy awareness while adapting to changing network conditions. However, it is more difficult to apply and necessitates the synchronization of numerous criteria [66].

3.2.2. Cluster Head Selection Strategies. Cluster head selection is an important feature of wireless sensor network (WSN) routing methods, influencing network efficiency and lifetime [67]. It entails designating selected nodes to serve as cluster leaders, in charge of data gathering, processing, and communication with the base station. Effective selection algorithms enable balanced energy usage because cluster chiefs do more

communication duties than normal nodes. Rotating roles or selecting nodes depending on residual energy, connection, or load helps to prevent early energy depletion, hence increasing network longevity. Proper cluster heads improve data transmission efficiency and network dependability. Random Selection is Simple and easy to construct, and it assures fairness over time by allowing all nodes to become cluster chiefs. However, energy consumption may not be optimized, which can result in inefficient cluster head placement [68]. Weighted Selection allows the selection of more capable nodes to improve energy efficiency, network lifetime, and overall performance, but it might cause selection bias if not balanced [69]. Rotational Selection balances energy usage across all nodes and prevents individual nodes from running out of energy soon. Requires synchronization and coordination for head rotation, which may result in greater control overhead [70].

3.2.3. Data Aggregation Strategies. Data aggregation algorithms in Wireless Sensor Networks (WSNs) are critical for saving energy and increasing network efficiency [71]. These solutions aggregate data from several sensor nodes to decrease redundancy and save transmission load [72]. Averaging or summarising sensor signals is a simple procedure, but it may result in the loss of detailed information. Hierarchical aggregation incorporates numerous stages of aggregation, which is economical for large networks but may cause delays. Adaptive aggregation automatically modifies the process based on network conditions and data correlation, which improves performance but necessitates complicated algorithms. These solutions improve the energy efficiency, scalability, and dependability of WSNs [73].

Simple Aggregation reduces the amount of data transmitted to the base station. But may lose detailed information [74]. Hierarchical Aggregation data is aggregated at multiple levels (within clusters and between clusters) before being transmitted to the base station, which further reduces data transmission and can handle larger networks efficiently. But as a complex aggregation process and increased delay due to multiple aggregation stages [75]. Moreover, adaptive aggregation optimizes aggregation based on real-time conditions and improves overall network performance. Requires dynamic adaptation mechanisms and increased computational overhead [76]. WSNs use MAC and Cluster-Based Protocols to optimize communication and energy consumption. MAC protocols employ a variety of channel assignment techniques to reduce interference and increase throughput. NOMA and Hybrid Multiplexing maximize efficiency by combining access modes. Random Access Protocols optimize channel use using strategies such as Individual and Random Assignment,

Static Uniform Distribution, and Load-Balanced Assignment. Cluster-based protocols group nodes into clusters for scalability and energy efficiency. Cluster Formation Strategies, including Distance-Based Clustering, Energy-Based Clustering, and Hybrid Clustering, aid in the formation of optimal clusters. Cluster Head Selection Strategies, such as Random Selection, Weighted Selection, and Rotational Selection, select nodes to coordinate clusters while balancing energy consumption. Data Aggregation Strategies eliminate redundant data transmissions, which saves energy. Combining these tactics can result in strong WSN solutions that balance throughput and latency.

4. Results and Discussion. The parameters for a wireless sensor network (WSN) simulation are as below. The network spans a 100 m × 100 m area and contains 100 nodes. The base station coordinates the network at 150, 50. Each node has a starting energy of 2 joules. Data packets are 6400 bits in size, and control information packets are 200 bits. The transceiver energy is 50 nJ/bit, whereas data aggregation is 5 nJ/bit/signal. There are two types of amplifier energies: open space (10 pJ/bit/m²) for short distances, and 0.0013 pJ/bit/m⁴ for longer distances with multipath fading. To prevent early depletion, a threshold of 0.05 joules is specified.

The Figure 4 compares the performance of RAP and TPP in terms of latency (cycles per packet) and throughput (packets per cycle). The latency is plotted on a logarithmic scale on the left y-axis (orange), while throughput is shown on the right y-axis (green).




Fig. 4. Comparing the throughput and latency of Random-Access Protocols (RAP) and Token Passing Protocols (TPP)

RAP1, RAP2, RAP3: These protocols show lower median latencies, clustered around $10110^{\wedge}1101$ cycles per packet, with RAP3 exhibiting a slightly higher spread. The median values for RAP1, RAP2, and RAP3 are consistent and low, but there are several outliers, indicated by red crosses, reaching up to $10210^{\wedge}2102$ cycles per packet.

TPP1, TPP2, TPP3: These protocols have a higher median latency compared to RAP protocols, with medians slightly above $10110^{\wedge}1101$. TPP3 has the highest spread and the most variability among the TPP protocols. Similar to RAP, there are outliers for TPP protocols, but they are less frequent and lower in magnitude.

RAP1, RAP2, RAP3: These protocols demonstrate higher throughput values, clustered around 0.5 packets per cycle. RAP2 and RAP3 have slightly lower throughput compared to RAP1, but all maintain relatively high performance.

TPP1, TPP2, TPP3: These protocols exhibit lower throughput values compared to RAP protocols, clustered around 0.2 packets per cycle. TPP3 has a slightly higher median throughput among TPP protocols but remains significantly lower than RAP protocols.

RAP protocols generally offer lower latency and higher throughput, making them suitable for applications requiring quick and efficient data transmission. Conversely, TPP protocols, with their higher latency and lower throughput, might be preferred in scenarios where controlled and orderly access to the network is necessary, despite the trade-off in speed and efficiency.

The Figure 5 illustrates a comparative analysis of multiple access techniques, focusing on latency and throughput. The access techniques compared are FDMA, TDMA, CDMA, SDMA, OFDMA, NOMA, and a Hybrid method. In terms of latency, FDMA and TDMA exhibit relatively low median values and less variability, indicating more consistent performance with fewer outliers. CDMA shows a slightly higher spread and median latency compared to FDMA and TDMA. SDMA presents a noticeable increase in both median latency and spread, while OFDMA and NOMA display the highest median latency and significant variability, with many outliers indicating instances of very high latency. The Hybrid method also shows high variability in latency, comparable to NOMA. Regarding throughput, OFDMA and NOMA outperform the other techniques, achieving the highest throughput values of around 0.7 and 0.65 packets per cycle, respectively. FDMA and TDMA have moderate throughput, approximately 0.4 and 0.5 packets per cycle. CDMA's throughput is similar to TDMA, while SDMA's throughput is slightly lower at around 0.35 packets per cycle. The Hybrid method, despite its widespread in latency, has the lowest throughput, around 0.3 packets per cycle.




Fig. 5. Comparative analysis of multiple access techniques using various multiplexing protocols

Tables 2, 3, and 4 provide a comparative overview of the different strategies used in clustering and data aggregation in wireless sensor networks. The comparison tables for Cluster Formation Strategies, Cluster Head Selection Strategies, and Data Aggregation Strategies provide a comprehensive overview of various methods used in wireless sensor networks (WSNs). Distance-Based Clustering, Energy-Based Clustering, and Hybrid Clustering each offer unique advantages, with Hybrid Clustering showing the highest energy efficiency and stability. Similarly, Cluster Head Selection Strategies such as Random, Weighted, and Rotational Selection balance fairness and energy efficiency, with Weighted Selection being particularly advantageous in large-scale networks. Data Aggregation Strategies like Simple Aggregation, Hierarchical Aggregation, and Adaptive Aggregation cater to different network complexities, with Hierarchical and Adaptive Aggregation providing high accuracy and scalability. Future research can focus on optimizing these strategies by integrating machine learning techniques for dynamic clustering and aggregation, improving real-time decision-making, and enhancing the adaptability of protocols to various network conditions. Additionally, exploring hybrid approaches that combine the strengths of different strategies could further enhance the energy efficiency, reliability, and scalability of WSNs, making them more robust.

Table 2. Comparison of various cluster formation strategies

Criteria	Distance-Based Clustering	Energy-Based Clustering	Hybrid Clustering
Definition	Forms clusters based on the proximity of nodes to each other.	Forms clusters based on the residual energy of nodes.	Combines both distance and energy metrics for clustering.
Complexity	Low	Medium	High
Energy Efficiency	Medium	High	Very High
Scalability	High	Medium	Medium
Cluster Stability	Low to Medium	High	High
Latency	Medium	Low	Low to Medium
Typical Applications	Small-scale networks, where node distribution is dense.	Networks with varying node energy levels.	Large-scale and heterogeneous networks.
Example Protocols	LEACH	DEEC	HEED
Values (Energy Consumption per Node)	2.5 J	1.8 J	1.2 J

Table 3. Comparison of various cluster head selection strategies

Criteria	Random Selection	Weighted Selection	Rotational Selection
Definition	Cluster heads are chosen randomly among nodes.	Cluster heads are chosen based on a weighted metric (e.g., energy level, connectivity).	Cluster head role rotates among nodes in a predetermined manner.
Fairness	Low	High	High
Energy Efficiency	Low to Medium	High	Medium
Load Balancing	Low	High	High
Cluster Stability	Low	Medium	Medium
Latency	Medium	Low	Low
Typical Applications	Simple and small networks.	Large-scale networks with variable node capabilities.	Networks requiring balanced energy consumption.
Example Protocols	LEACH	SEP	HEED
Values (Energy Consumption per Node)	3.0 J	2.0 J	2.5 J

Table 4. Comparison of various data aggregation strategies

Criteria	Simple Aggregation	Hierarchical Aggregation	Adaptive Aggregation
Definition	Basic aggregation method where data is simply combined.	Data is aggregated in a hierarchical manner, often through multiple levels.	Data aggregation method adapts based on network conditions and data characteristics.
Complexity	Low	High	Medium
Energy Efficiency	Low to Medium	High	High
Latency	Low	High	Medium
Accuracy	Low to Medium	High	High
Scalability	Medium	High	High
Typical Applications	Simple and small networks.	Large-scale and multi-hop networks.	Dynamic and heterogeneous networks.
Example Protocols	LEACH	PEGASIS	ADA
Values (Energy Consumption per Node)	3.0 J	1.8 J	2.0 J

Despite their advantages in reducing interference and increasing throughput, Multi-Channel MAC protocols face several limitations. FDMA lacks flexibility and can lead to inefficient spectrum usage under varying network conditions. TDMA requires precise synchronization, which can be challenging in large-scale networks. CDMA can suffer from code management complexity and increased overhead. Techniques like OFDMA and NOMA, while efficient, introduce significant computational complexity and require sophisticated hardware. Additionally, Random Access Protocols may result in high collision rates under heavy traffic, and Token Passing Protocols can introduce latency due to the sequential nature of token circulation.

Cluster-based protocols increase scalability and energy efficiency, but they have limits. Distance-Based Clustering might produce unbalanced clusters, whereas Energy-Based Clustering ignores ideal communication pathways, resulting in inferior network performance. Hybrid clustering incorporates numerous techniques while increasing complexity. Random selection does not ensure energy efficiency, whereas weighted and rotational selections necessitate additional overhead. Simple aggregation may not minimize redundancy in diverse networks, but hierarchical aggregation causes latency. Adaptive Aggregation necessitates sophisticated algorithms that dynamically react to network conditions.

A hybrid strategy that combines Multi-Channel MAC with Cluster-Based Protocols can boost network performance. This entails combining TDMA with Energy-Based Clustering to maximize time and energy resources. CDMA with Hybrid Clustering improves spectrum efficiency and balanced cluster formation. Random Access Protocols' Load-Balanced Assignment methods can reduce energy usage by dispersing communication loads more equally. OFDMA's hierarchical aggregation decreases data redundancy while maximizing spectrum usage. These hybrid approaches can result in robust WSNs that balance throughput, latency, and energy efficiency, enabling long-term and efficient network operations across a wide range of applications (Table 5).

Table 5. Comparative performance analysis of various multiple access techniques

Method	Latency (ms)	Throughput (Mbps)	Energy Efficiency (bits/J)
FDMA	15	4	1.5
TDMA	30	3	1.2
CDMA	12	8	2.0
SDMA	8	25	4.0
OFDMA	10	40	5.5
NOMA	8	55	6.0
Hybrid	7	60	6.5

In our comparative analysis, traditional orthogonal multiple-access schemes such as FDMA and TDMA exhibit higher latencies and lower throughput, with FDMA showing a latency of about 15 ms and throughput of around 4 Mbps, while TDMA suffers from even higher delay (approximately 30 ms) and delivers roughly 3 Mbps; both methods yield modest energy efficiencies of about 1.5 and 1.2 bits per joule respectively. In contrast, CDMA by enabling simultaneous transmissions over the entire bandwidth through unique spreading codes reduces latency to around 12 ms and doubles throughput to nearly 8 Mbps, achieving an energy efficiency of approximately 2.0 bits/J. Advancements in spatial and frequency domain techniques are reflected in SDMA and OFDMA; SDMA leverages multiple antennas to serve users in different spatial regions, thereby reducing latency to 8 ms, increasing throughput to about 25 Mbps, and boosting energy efficiency to roughly 4.0 bits/J, while OFDMA's dynamic subcarrier allocation pushes these figures further to 10 ms latency, 40 Mbps throughput, and 5.5 bits/J energy efficiency. The introduction of NOMA, which exploits power-domain multiplexing and relies on successive interference cancellation, achieves even lower delays (around 8 ms) and

significantly higher throughput (about 55 Mbps), with energy efficiency climbing to roughly 6.0 bits/J. A hybrid approach that combines the strengths of OFDMA, SDMA, and NOMA further minimizes latency (down to about 7 ms), maximizes throughput (approximately 60 Mbps), and optimizes energy usage (around 6.5 bits/J), thereby offering a promising solution for next-generation wireless networks where ultra-low delay, high data rates, and superior energy performance are critical.

5. Conclusion. Cluster-based routing algorithms are critical for increasing the efficiency and scalability of wireless sensor networks (WSNs). Different clustering algorithms, including distance-based clustering, energy-based clustering, hybrid clustering, random cluster head selection, weighted selection, rotating selection, simple aggregation, hierarchical aggregation, and adaptive aggregation, each have their own set of advantages and disadvantages. Distance-based clustering can create unbalanced clusters, whereas energy-based and hybrid clustering enhance energy efficiency but necessitate coordination. Data aggregation techniques must be adopted according to network and data needs. Future research should concentrate on creating adaptive, scalable, and energy-efficient cluster-based routing protocols.

References

1. Shah S.M., Sun Z., Zaman K., Hussain A., Ullah I., Ghadi Y.Y., Khan M.A., Nasimov R. Advancements in neighboring-based energy-efficient routing protocol (NBEER) for underwater wireless sensor networks. *Sensors*. 2023. vol. 23(13). DOI: 10.3390/s23136025.
2. Raj V.P., Duraipandian M. Energy conservation using PISAE and cross-layer-based opportunistic routing protocol (CORP) for wireless sensor network. *Engineering Science and Technology, an International Journal*. 2023. vol. 42.
3. Duy Tan N., Nguyen D.N., Hoang H.N., Le T.T.H. EEGT: Energy efficient grid-based routing protocol in wireless sensor networks for IoT applications. *Computers*. 2023. vol. 12(5).
4. Abdulai J.D., Adu-Manu K.S., Katsriku F.A., Engmann F. A modified distance-based energy-aware (mDBEA) routing protocol in wireless sensor networks (WSNs). *Journal of Ambient Intelligence and Humanized Computing*. 2023. vol. 14(8). pp. 10195–10217.
5. Manikandan A., Venkataramanan C., Dhanapal R. A score based link delay aware routing protocol to improve energy optimization in wireless sensor network. *Journal of Engineering Research*. 2023. vol. 11(4). pp. 404–413.
6. Gururaj H.L., Natarajan R., Almujaally N.A., Flammini F., Krishna S., Gupta, S.K. Collaborative energy-efficient routing protocol for sustainable communication in 5G/6G wireless sensor networks. *IEEE Open Journal of the Communications Society*. 2023. pp. 2050–2061.
7. Narayan V., Daniel A.K., Chaturvedi P. E-FEERP: Enhanced fuzzy based energy efficient routing protocol for wireless sensor network. *Wireless Personal Communications*. 2023. vol. 131(1). pp. 371–398. DOI: 10.1007/s11277-023-10434-z.

8. Hemanand D., Senthilkumar C., Saleh O.S., Muthuraj B., Anand A., Velmurugan V. Analysis of power optimization and enhanced routing protocols for wireless sensor networks. *Measurement: Sensors*. 2023. vol. 25. DOI: 10.1016/j.measen.2022.100610.
9. Sharma A., Babbar H., Rani S., Sah D.K., Sehar S., Gianini G. MHSEER: a meta-heuristic secure and energy-efficient routing protocol for wireless sensor network-based industrial IoT. *Energies*. 2023. vol. 16(10). DOI: 10.3390/en16104198.
10. Verma C.P. Enhancing Parameters of LEACH Protocol for Efficient Routing in Wireless Sensor Networks. *Journal of Computers, Mechanical and Management*. 2023. vol. 2(1). pp. 30–34. DOI: 10.57159/gadljcm.2.1.23040.
11. Li G., Peng S., Wang C., Niu J., Yuan Y. An energy-efficient data collection scheme using denoising autoencoder in wireless sensor networks. *Tsinghua Science and Technology*. 2019. vol. 24(1). pp. 86–96. DOI: 10.26599/TST.2018.9010002.
12. Panchal A., Singh R.K. EEHCHR: Energy efficient hybrid clustering and hierarchical routing for wireless sensor networks. *Ad Hoc Netw.* 2021. vol. 123. DOI: 10.1016/j.adhoc.2021.102692.
13. Wang J., Han H., Li H., He S., Sharma P.K., Chen L. Multiple strategies differential privacy on sparse tensor factorization for network traffic analysis in 5G, *IEEE Trans. Ind. Inform.* 2022. vol. 18(3). pp. 1939–1948. DOI: 10.1109/TII.2021.3082576.
14. Cao D., Zheng B., Ji B., et al. A robust distance-based relay selection for message dissemination in vehicular network, *Wirel. Netw.* 2018. vol. 26. pp. 1755–1771. DOI: 10.1007/s11276-018-1863-4.
15. Raja S.P., Rajkumar T.D., Raj V. Internet of things: Challenges, issues and applications, *J. Circuits Syst. Comput.* 2018. vol. 27. DOI: 10.1142/S0218126618300076.
16. Chandramohan K., Manikandan A., Ramalingam S., Dhanapal R. Performance evaluation of VANET using Directional Location Aided Routing (D-LAR) protocol with sleep scheduling algorithm. *Ain Shams Eng. J.* 2024. vol. 15(3). DOI: 10.1016/j.asej.2023.102458.
17. Premakumari S.B.N., Mohan P., Subramanian K. An enhanced localization approach for energy conservation in wireless sensor network with Q deep learning algorithm. *Symmetry*. 2022. vol. 14. DOI: 10.3390/sym14122515.
18. Lilhore U.K., Khalaf O.I., Simaiya S., Tavera Romero C.A., Abdulsahib G.M., Poongodi M., Kumar D. A depth-controlled and energy-efficient routing protocol for underwater wireless sensor networks. *International Journal of Distributed Sensor Networks*. 2022. vol. 18. no. 9. DOI: 10.1177/15501329221117118.
19. Karpagalakshmi R.C., Vijayalakshmi P., Gowsic K., Rath R. An effective traffic management system using Connected Dominating Set Forwarding (CDSF) framework for reducing traffic congestion in high density VANETs. *Wirel. Pers. Commun.* 2021. vol. 119(3). pp. 2725–2754.
20. Manikandan A., Madhu G.C., Flora G.D., et al. Hybrid advisory weight based dynamic scheduling framework to ensure effective communication using acknowledgement during encounter strategy in Ad-hoc network. *Int. J. Inf. Technol.* 2023. vol. 15. pp. 4521–4527. DOI: 10.1007/s41870-023-01421-5.
21. Elbhiri B., Saadane R., El Fkihiani S., Aboutajdine D. Developed Distributed Energy-Efficient Clustering (DDEEC) for heterogeneous wireless sensor networks. *I/V Communications and Mobile Network (ISVC)*. 5th International Symposium on I/V Communications and Mobile Network. 2010. 1-4. DOI: 10.1109/ISVC.2010.5656252.
22. Saini P., Sharma A.K. E-DEEC – Enhanced Distributed Energy Efficient Clustering Scheme for heterogeneous WSN. *1st International Conference on Parallel, Distributed and Grid Computing*. 2010. pp. 205–210. DOI: 10.1109/PDGC.2010.5679898.

23. Saini P., Sharma A.K. Energy Efficient Scheme for Clustering Protocol Prolonging the Lifetime of Heterogeneous Wireless Sensor Networks. *International Journal of Computer Applications*. 2010. vol. 6(2). pp. 30–36.
24. Javaid N., Qureshi T.N., Khan A.H., Iqbal A., Akhtar E., Ishfaq M. EDDEEC: Enhanced Developed Distributed Energy-efficient Clustering for Wireless Sensor Networks. *Procedia Computer Science*. 2013. vol. 19. pp. 914–919.
25. Jibreel F. Improved Developed Distributed Energy-Efficient Clustering Scheme (iDDEEC). *International Journal of Innovative Science and Research Technology*. 2018. vol. 3(12). pp. 564–567.
26. Jibreel F., Daabo M.I., Yusuf-Asaju A.W., Gbolagade K.A. Servant-MODLEACH Energy Efficient Cluster Based Routing Protocol for Large Scale Wireless Sensor Network. *The 12th International MultiConference on ICT Applications*. 2018. vol. 12. pp. 1–6.
27. Jibreel F. Gateway-based Threshold Distributed Energy Efficient Clustering (GTDEEC). *International Journal of Computer Applications*. 2019. vol. 182(42). pp. 43–46.
28. Smaragdakis G, Matta I, Bestavros A. SEP: A stable election protocol for clustered heterogeneous wireless sensor networks. *Proceeding of the International Workshop on Sensor and Actor Network Protocols and Applications*. 2004. no. 4. pp. 660–670.
29. Kosunalp S., Acik S. Medium Access Control Layer for Internet of Things Edge-Side Network Using Carrier-Sense Multiple Access Protocol. *Engineering Proceedings*. 2024. vol. 70(1).
30. Ahmad S.S., Al-Raweshidy H., Nilavalan R. Investigating delay of the media access control protocols for IoT-RoF using quantum entanglement. *IET Networks*. 2024. vol. 13(4). pp. 324–337.
31. Beltramelli L., Mahmood A., Osterberg P., Gidlund M. LoRa beyond ALOHA: An investigation of alternative random access protocols. *IEEE Transactions on Industrial Informatics*. 2020. vol. 17(5). pp. 3544–3554.
32. Nagaraju S., Gudino L.J., Sood N., Chandran J.G., Sreejith V. Multiple token-based neighbor discovery for directional sensor networks. *ETRI Journal*. 2020. vol. 42(3). pp. 351–365.
33. Dhabliya D., Soundararajan R., Selvarasu P., Balasubramaniam M.S., Rajawat A.S., Goyal S.B., Raboaca M.S., Mihaltan T.C., Suciu G. Energy-efficient network protocols and resilient data transmission schemes for wireless sensor Networks – An experimental survey. *Energies*. 2022. vol. 15(23). DOI: 10.3390/en15238883.
34. Azad M.A.K., Ngo C.T., Oh H. A two-channel slotted sense multiple access protocol for timely and reliable data transmission in industrial wireless sensor networks. *International Journal of Distributed Sensor Networks*. 2020. vol. 16(4). DOI: 10.1177/1550147720902007.
35. Rambabu C., Prasad, V.V.K.D.V., Prasad K.S. Multipath cluster-based hybrid MAC protocol for wireless sensor networks. *International Journal of Wireless and Microwave Technologies (IJWMT)*. 2020. vol. 10(1). pp. 1–16.
36. Alam M.I.I., Hossain M.F., Munasinghe K., Jamalipour A. MAC protocol for underwater sensor networks using EM wave with TDMA based control channel. *IEEE Access*. 2020. vol. 8. pp. 168439–168455.
37. Arafath M.S., Qamar S., Khan K.U.R., Sunitha, K.V.N. Analysis of Power in Medium Access Control Code Division Multiple Access Protocol for Data Collection in a Wireless Sensor Network. *Innovations in Electronics and Communication Engineering: Proceedings of the 8th ICIECE 2019*. 2020. pp. 39–50.
38. Ouadou M., Mafamane R., Minaoui K. A Hybrid Anti-Collision Protocol Based on Frequency Division Multiple Access (FDMA) and Time Division Multiple Access

- (TDMA) for Radio Frequency Identification (RFID) Readers. *Network*. 2024. vol. 4(2). pp. 217–236.
39. Li D., Nakazato J., Tsukada M. A State-Interactive MAC Layer TDMA Protocol Based on Smart Antennas. *Electronics*. 2024. vol. 13(11).
 40. Longla T.T., Shah A.S., Rabie K.M., Li X. S-LEACH-CDMA: Sectoring and CDMA Integration with LEACH for Scalability and Energy Efficiency in Wireless Sensor Networks. *Authorea Preprints*. 2024.
 41. Maeng J., Dahouda M.K., Joe I. Optimal power allocation with sectored cells for sum-throughput maximization in wireless-powered communication networks based on hybrid SDMA/NOMA. *Electronics*. 2022. vol. 11(6).
 42. Peng M., Li B., Yan Z., Yang M. A spatial group-based multi-user full-duplex OFDMA MAC protocol for the next-generation WLAN. *Sensors*. 2020. vol. 20(14).
 43. Ghosh S., Al-Dweik A., Alouini M.S. On the performance of end-to-end cooperative NOMA-based IoT networks with wireless energy harvesting. *IEEE Internet of Things Journal*. 2023. vol. 10(18). pp. 16253–16270.
 44. Esmail H., Sun H. Energy Harvesting for TDS-OFDM in NOMA-Based Underwater Communication Systems. *Sensors*. 2022. vol. 22(15). DOI: 10.3390/s22155751.
 45. Pandi V.S., Prasina A., Shibu S., Sripriya T. A Novel Downlink Frequency Allocation (DFA) Technique for Enhanced Throughput in 5G and Beyond (B5G) Multi-hop Networks. *Traitement du Signal*. 2024. vol. 41(3). pp. 1345–1354.
 46. Yu N., Zhang L., Ren Y. BRS-based robust secure localization algorithm for wireless sensor networks. *International Journal of Distributed Sensor Networks*. 2013. vol. 9(3). DOI: 10.1155/2013/107024.
 47. Mestres A., Abadal S., Torrellas J., Alarcon E., Cabellos-Aparicio A. A MAC protocol for reliable broadcast communications in wireless network-on-chip. *Proceedings of the 9th International Workshop on Network on Chip Architectures*. 2016. pp. 21–26. DOI: 10.1145/2994133.2994137.
 48. Li X., Xiao F., Tang K., Luo E. Outage performance and energy efficiency optimization of wireless-powered millimeter-wave sensor networks. *EURASIP Journal on Wireless Communications and Networking*. 2024. vol. 2024(1). DOI: 10.1186/s13638-023-02328-2.
 49. Gulyamov S., Yusupbekov A., Mirzaev D., Kuziev Z. Algorithms for composing communication protocols of wireless sensor networks with random access. *E3S Web of Conferences*. 2023. vol. 417.
 50. Dhabliya D., Soundararajan R., Selvarasu P., Balasubramaniam M.S., Rajawat A.S., Goyal S.B., Raboaca M.S., Mihaltan T.C., Verma C., Suci G. Energy-efficient network protocols and resilient data transmission schemes for wireless sensor Networks – An experimental survey. *Energies*. 2022. vol. 15(23). DOI: 10.3390/en15238883.
 51. Thahniyath G., Jayaprasad M. Secure and load balanced routing model for wireless sensor networks. *Journal of King Saud University-Computer and Information Sciences*. 2022. vol. 34(7). pp. 4209–4218.
 52. Ndoye E.H.M., Diallo O., Hakem N., Jacquet F., Misson M., Rodrigues J.J. Interference-aware clustering approach improving QoS for linear WSNs using a token-based MAC protocol. *International Journal of Communication Systems*. 2020. vol. 33(11).
 53. Nagaraju S., Gudino L.J., Sood N., Chandran J.G., Sreejith V. Multiple token-based neighbor discovery for directional sensor networks. *ETRI Journal*. 2020. vol. 42(3). pp. 351–365.
 54. Mundada M.R., Kiran S., Khobanna S., Varsha R.N., George S.A. A study on energy efficient routing protocols in wireless sensor networks. *International Journal of Distributed and Parallel Systems (IJDPS)*. 2012. vol. 3. pp. 311–330.

55. Anees J., Zhang H.C., Lougou B.G., Baig S., Dessie Y.G. Delay aware energy-efficient opportunistic node selection in restricted routing. *Computer Networks*. 2020. vol. 181.
56. Lee D., Attias R., Puri A., Sengupta R., Tripakis S., Varaiya P. A wireless token ring protocol for intelligent transportation systems. *IEEE Intelligent Transportation Systems. Proceedings (ITSC 2001)*. IEEE, 2001. pp. 1152–1157.
57. Hang Z., Bo L., Zhongjiang Y., Mao Y., Xinru L. A multi-token sector antenna neighbor discovery protocol for directional ad hoc networks. *China Communications*. 2024.
58. Maurya S., Gupta V., Jain V.K. Lbrr: Load balanced ring routing protocol for heterogeneous sensor networks with sink mobility. *IEEE wireless communications and networking Conference (WCNC)*. IEEE, 2017. pp. 1–6.
59. Cevik T., Zaim A.H. EETBR: Energy efficient token-based routing for wireless sensor networks. *Turkish Journal of Electrical Engineering and Computer Sciences*. 2013. vol. 21(2). pp. 513–526.
60. Han B., Ran F., Li J., Yan L., Shen H., Li A. A novel adaptive cluster based routing protocol for energy-harvesting wireless sensor networks. *Sensors*. 2022. vol. 22(4).
61. Qureshi K.N., Bashir M.U., Lloret J., Leon A. Optimized cluster-based dynamic energy-aware routing protocol for wireless sensor networks in agriculture precision. *Journal of sensors*. 2020. vol. 2020(1).
62. Hu H., Fan X., Wang C. Efficient cluster-based routing protocol for wireless sensor networks by using collaborative-inspired Harris Hawk optimization and fuzzy logic. *Plos one*. 2024. vol. 19(4).
63. Wang H., Liu K., Wang C., Hu H. Energy-Efficient, Cluster-Based Routing Protocol for Wireless Sensor Networks Using Fuzzy Logic and Quantum Annealing Algorithm. *Sensors*. 2024. vol. 24(13).
64. El Habib Kahla M., Beggas M., Laouid A., Hammoudeh M. A Nature-Inspired Partial Distance-Based Clustering Algorithm. *Journal of Sensor and Actuator Networks*. 2024. vol. 13(4).
65. Sundararajan R.K., Jayaraman G., Arunkumar S., Jeyapandian M., Kaliyaperumal K., Perumal D., Dhulipala V.S. EECAS: Energy Efficient Clustering and Aggregator Node Selection for Wireless Sensor Networks. *Wireless Personal Communications*. 2024. vol. 136. pp. 899–919.
66. Preetha M., Anil Kumar N., Elavarasi K., Vignesh T., Nagaraju V. A Hybrid Clustering Approach Based Q-Leach in TDMA to Optimize QOS-Parameters. *Wireless Personal Communications*. 2022. pp. 1–32.
67. Akila E., Deepa B. An Comparison of Different Cluster Head Selection Techniques for Wireless Sensor Networks. *Communications on Applied Nonlinear Analysis*. 2024. vol. 31(5s). pp. 479–486.
68. Tay M., Senturk A. A new energy-aware cluster head selection algorithm for wireless sensor networks. *Wireless Personal Communications*. 2022. vol. 122(3). pp. 2235–2251.
69. Sen S., Sahoo L., Ghosh S.L. Lifetime extension of wireless sensor networks by perceptive selection of cluster head using K-Means and Einstein weighted averaging aggregation operator under uncertainty. *J. Ind Intell*. 2024. vol. 2(1). pp. 54–62.
70. Ahmad R., Wazirali R., Bsoul Q., Abu-Ain T., Abu-Ain W. Feature-selection and mutual-clustering approaches to improve DoS detection and maintain WSNs' lifetime. *Sensors*. 2021. vol. 21(14).
71. Begum B.A., Nandury S.V. Data aggregation protocols for WSN and IoT applications – A comprehensive survey. *Journal of King Saud University-Computer and Information Sciences*. 2023. vol. 35(2). pp. 651–681.

72. Jan S.R.U., Khan R., Jan M.A. An energy-efficient data aggregation approach for cluster-based wireless sensor networks. *Annals of telecommunications*. 2021. vol. 76(5). pp. 321–329.
73. Sharmin S., Ahmedy I., Md Noor R. An energy-efficient data aggregation clustering algorithm for wireless sensor Networks using hybrid PSO. *Energies*. 2023. vol. 16(5).
74. Sreedevi P., Venkateswarlu S. An Efficient Intra-Cluster Data Aggregation and finding the Best Sink location in WSN using EEC-MA-PSOGA approach. *International Journal of Communication Systems*. 2022. vol. 35(8).
75. Khedr A.M., Raj P.P., Al Ali A. An Energy-Efficient Data Acquisition Technique for Hierarchical Cluster-Based Wireless Sensor Networks. *J. Wirel. Mob. Networks Ubiquitous Comput. Dependable Appl.* 2020. vol. 11(3). pp. 70–86.
76. Jawaligi S.S. ACRDA: An adaptive combined relay based dynamic data aggregation technique for wireless sensor networks. *Measurement: Sensors*. 2022. vol. 24.

Pawale Sushma P. — Professor, Department of computer science, Visvesvaraya Technological University-RRC. Research interests: computer science. The number of publications — 5. sushmap9feb@gmail.com; QFH7+497 Jnana Sangama, VTU Main Rd., 590018, Machhe, Belagavi, Karnataka, India; office phone: +91(0831)249-8225.

Patil Poornima G. — Professor, Department of computer science, Visvesvaraya Technological University-RRC. Research interests: computer science. The number of publications — 5. poornima_g_patil@yahoo.com; QFH7+497 Jnana Sangama, VTU Main Rd., 590018, Machhe, Belagavi, Karnataka, India; office phone: +91(0831)249-8225.

С. ПАВАЛЕ, П. ПАТИЛ
**КОМПЛЕКСНЫЙ АНАЛИЗ МНОГОКАНАЛЬНЫХ МАС-
ПРОТОКОЛОВ И КЛАСТЕРНЫХ ПРОТОКОЛОВ
ДЛЯ СОЗДАНИЯ НАДЕЖНЫХ И ЭНЕРГОЭФФЕКТИВНЫХ
БЕСПРОВОДНЫХ СЕНСОРНЫХ СЕТЕЙ**

Павале С., Патил П. Комплексный анализ многоканальных МАС-протоколов и кластерных протоколов для создания надежных и энергоэффективных беспроводных сенсорных сетей.

Аннотация. Беспроводные сенсорные сети (WSN) стали незаменимыми в различных областях применения, от мониторинга окружающей среды до отслеживания состояния здоровья. По мере их развития вопросы безопасности и энергоэффективности остаются приоритетными. В данной аналитической работе проводится сравнение современных методов в рамках двух ключевых категорий протоколов: многоканальных протоколов управления доступом к среде (MAC) и кластерных протоколов. Оценка сосредоточена на различных стратегиях назначения каналов и методах кластеризации, включая статическое и динамическое распределение ресурсов связи, адаптивные методологии и гибридные подходы, а также стратегии выбора и ротации кластерных центров и эффективного агрегирования данных. С помощью комплексного исследования мы выделяем ограничения и потенциал каждого подхода, предлагая гибридную структуру, которая объединяет преимущества обоих типов протоколов для повышения безопасности и энергоэффективности в беспроводных сенсорных сетях. Результаты исследования показывают, что интеграция динамического распределения ресурсов с энергоэффективной кластеризацией и адаптивными стратегиями с ротацией кластерных голов может привести к более надежным и эффективным реализациям. Данный анализ служит основой для будущих исследований, направленных на разработку усовершенствованных гибридных протоколов, которые отвечают динамическим требованиям WSN, обеспечивая устойчивую и эффективную работу сети.

Ключевые слова: беспроводные сенсорные сети (WSN), протоколы многоканального управления доступом к среде (MAC), кластерные протоколы, безопасность, энергоэффективность.

Литература

1. Shah S.M., Sun Z., Zaman K., Hussain A., Ullah I., Ghadi Y.Y., Khan M.A., Nasimov R. Advancements in neighboring-based energy-efficient routing protocol (NBEER) for underwater wireless sensor networks. *Sensors*. 2023. vol. 23(13). DOI: 10.3390/s23136025.
2. Raj V.P., Duraipandian M. Energy conservation using PISAE and cross-layer-based opportunistic routing protocol (CORP) for wireless sensor network. *Engineering Science and Technology, an International Journal*. 2023. vol. 42.
3. Duy Tan N., Nguyen D.N., Hoang H.N., Le T.T.H. EEGT: Energy efficient grid-based routing protocol in wireless sensor networks for IoT applications. *Computers*. 2023. vol. 12(5).
4. Abdulai J.D., Adu-Manu K.S., Katsriku F.A., Engmann F. A modified distance-based energy-aware (mDBEA) routing protocol in wireless sensor networks (WSNs). *Journal of Ambient Intelligence and Humanized Computing*. 2023. vol. 14(8). pp. 10195–10217.

5. Manikandan A., Venkataraman C., Dhanapal R. A score based link delay aware routing protocol to improve energy optimization in wireless sensor network. *Journal of Engineering Research*. 2023. vol. 11(4). pp. 404–413.
6. Gururaj H.L., Natarajan R., Almujaally N.A., Flammini F., Krishna S., Gupta, S.K. Collaborative energy-efficient routing protocol for sustainable communication in 5G/6G wireless sensor networks. *IEEE Open Journal of the Communications Society*. 2023. pp. 2050–2061.
7. Narayan V., Daniel A.K., Chaturvedi P. E-FEERP: Enhanced fuzzy based energy efficient routing protocol for wireless sensor network. *Wireless Personal Communications*. 2023. vol. 131(1). pp. 371–398. DOI: 10.1007/s11277-023-10434-z.
8. Hemanand D., Senthilkumar C., Saleh O.S., Muthuraj B., Anand A., Velmurugan V. Analysis of power optimization and enhanced routing protocols for wireless sensor networks. *Measurement: Sensors*. 2023. vol. 25. DOI: 10.1016/j.measen.2022.100610.
9. Sharma A., Babbar H., Rani S., Sah D.K., Sehar S., Gianini G. MHSEER: a meta-heuristic secure and energy-efficient routing protocol for wireless sensor network-based industrial IoT. *Energies*. 2023. vol. 16(10). DOI: 10.3390/en16104198.
10. Verma C.P. Enhancing Parameters of LEACH Protocol for Efficient Routing in Wireless Sensor Networks. *Journal of Computers, Mechanical and Management*. 2023. vol. 2(1). pp. 30–34. DOI: 10.57159/gadl.jcmm.2.1.23040.
11. Li G., Peng S., Wang C., Niu J., Yuan Y. An energy-efficient data collection scheme using denoising autoencoder in wireless sensor networks. *Tsinghua Science and Technology*. 2019. vol. 24(1). pp. 86–96. DOI: 10.26599/TST.2018.9010002.
12. Panchal A., Singh R.K. EEHCHR: Energy efficient hybrid clustering and hierarchical routing for wireless sensor networks. *Ad Hoc Netw.* 2021. vol. 123. DOI: 10.1016/j.adhoc.2021.102692.
13. Wang J., Han H., Li H., He S., Sharma P.K., Chen L. Multiple strategies differential privacy on sparse tensor factorization for network traffic analysis in 5G. *IEEE Trans. Ind. Inform.* 2022. vol. 18(3). pp. 1939–1948. DOI: 10.1109/TII.2021.3082576.
14. Cao D., Zheng B., Ji B., et al. A robust distance-based relay selection for message dissemination in vehicular network, *Wirel. Netw.* 2018. vol. 26. pp. 1755–1771. DOI: 10.1007/s11276-018-1863-4.
15. Raja S.P., Rajkumar T.D., Raj V. Internet of things: Challenges, issues and applications, *J. Circuits Syst. Comput.* 2018. vol. 27. DOI: 10.1142/S0218126618300076.
16. Chandramohan K., Manikandan A., Ramalingam S., Dhanapal R. Performance evaluation of VANET using Directional Location Aided Routing (D-LAR) protocol with sleep scheduling algorithm. *Ain Shams Eng. J.* 2024. vol. 15(3). DOI: 10.1016/j.asej.2023.102458.
17. Premakumari S.B.N., Mohan P., Subramanian K. An enhanced localization approach for energy conservation in wireless sensor network with Q deep learning algorithm. *Symmetry*. 2022. vol. 14. DOI: 10.3390/sym14122515.
18. Lilhore U.K., Khalaf O.I., Simaiya S., Tavera Romero C.A., Abdulsahib G.M., Poongodi M., Kumar D. A depth-controlled and energy-efficient routing protocol for underwater wireless sensor networks. *International Journal of Distributed Sensor Networks*. 2022. vol. 18. no. 9. DOI: 10.1177/1550132922111718.
19. Karpagalakshmi R.C., Vijayalakshmi P., Gowsic K., Rathi R. An effective traffic management system using Connected Dominating Set Forwarding (CDSF) framework for reducing traffic congestion in high density VANETs. *Wirel. Pers. Commun.* 2021. vol. 119(3). pp. 2725–2754.
20. Manikandan A., Madhu G.C., Flora G.D., et al. Hybrid advisory weight based dynamic scheduling framework to ensure effective communication using

- acknowledgement during encounter strategy in Ad-hoc network. *Int. J. Inf. Technol.* 2023. vol. 15. pp. 4521–4527. DOI: 10.1007/s41870-023-01421-5.
21. Elbhiri B, Saadane R, El Fkhiand S, Aboutajdine D. Developed Distributed Energy-Efficient Clustering (DDEEC) for heterogeneous wireless sensor networks. *I/V Communications and Mobile Network (ISVC)*. 5th International Symposium on I/V Communications and Mobile Network. 2010. 1-4. DOI: 10.1109/ISVC.2010.5656252.
22. Saini P., Sharma A.K. E-DEEC – Enhanced Distributed Energy Efficient Clustering Scheme for heterogeneous WSN. *1st International Conference on Parallel, Distributed and Grid Computing*. 2010. pp. 205–210. DOI: 10.1109/PDGC.2010.5679898.
23. Saini P., Sharma A.K. Energy Efficient Scheme for Clustering Protocol Prolonging the Lifetime of Heterogeneous Wireless Sensor Networks. *International Journal of Computer Applications*. 2010. vol. 6(2). pp. 30–36.
24. Javaid N., Qureshi T.N., Khan A.H., Iqbal A., Akhtar E., Ishfaq M. EDDEEC: Enhanced Developed Distributed Energy-efficient Clustering for Wireless Sensor Networks. *Procedia Computer Science*. 2013. vol. 19. pp. 914–919.
25. Jibreel F. Improved Developed Distributed Energy-Efficient Clustering Scheme (iDDEEC). *International Journal of Innovative Science and Research Technology*. 2018. vol. 3(12). pp. 564–567.
26. Jibreel F., Daabo M.I., Yusuf-Asaju A.W., Gbolagade K.A. Servant-MODLEACH Energy Efficient Cluster Based Routing Protocol for Large Scale Wireless Sensor Network. *The 12th International MultiConference on ICT Applications*. 2018. vol. 12. pp. 1–6.
27. Jibreel F. Gateway-based Threshold Distributed Energy Efficient Clustering (G-TDEEC). *International Journal of Computer Applications*. 2019. vol. 182(42). pp. 43–46.
28. Smaragdakis G, Matta I, Bestavros A. SEP: A stable election protocol for clustered heterogeneous wireless sensor networks. *Proceeding of the International Workshop on Sensor and Actor Network Protocols and Applications*. 2004. no. 4. pp. 660–670.
29. Kosunalp S., Acik S. Medium Access Control Layer for Internet of Things Edge-Side Network Using Carrier-Sense Multiple Access Protocol. *Engineering Proceedings*. 2024. vol. 70(1).
30. Ahmad S.S., Al-Raweshidy H., Nilavalan R. Investigating delay of the media access control protocols for IoT-RoF using quantum entanglement. *IET Networks*. 2024. vol. 13(4). pp. 324–337.
31. Beltramelli L., Mahmood A., Osterberg P., Gidlund M. LoRa beyond ALOHA: An investigation of alternative random access protocols. *IEEE Transactions on Industrial Informatics*. 2020. vol. 17(5). pp. 3544–3554.
32. Nagaraju S., Gudino L.J., Sood N., Chandran J.G., Sreejith V. Multiple token-based neighbor discovery for directional sensor networks. *ETRI Journal*. 2020. vol. 42(3). pp. 351–365.
33. Dhabliya D., Soundararajan R., Selvarasu P., Balasubramaniam M.S., Rajawat A.S., Goyal S.B., Raboaca M.S., Mihaltan T.C., Suciu G. Energy-efficient network protocols and resilient data transmission schemes for wireless sensor Networks – An experimental survey. *Energies*. 2022. vol. 15(23). DOI: 10.3390/en15238883.
34. Azad M.A.K., Ngo C.T., Oh H. A two-channel slotted sense multiple access protocol for timely and reliable data transmission in industrial wireless sensor networks. *International Journal of Distributed Sensor Networks*. 2020. vol. 16(4). DOI: 10.1177/1550147720902007.
35. Rambabu C., Prasad, V.V.K.D.V., Prasad K.S. Multipath cluster-based hybrid MAC protocol for wireless sensor networks. *International Journal of Wireless and Microwave Technologies (IJWMT)*. 2020. vol. 10(1). pp. 1–16.

36. Alam M.I.I., Hossain M.F., Munasinghe K., Jamalipour A. MAC protocol for underwater sensor networks using EM wave with TDMA based control channel. *IEEE Access*. 2020. vol. 8. pp. 168439–168455.
37. Arafath M.S., Qamar S., Khan K.U.R., Sunitha, K.V.N. Analysis of Power in Medium Access Control Code Division Multiple Access Protocol for Data Collection in a Wireless Sensor Network. *Innovations in Electronics and Communication Engineering: Proceedings of the 8th ICIECE 2019*. 2020. pp. 39–50.
38. Ouadou M., Mafamane R., Minaoui K. A Hybrid Anti-Collision Protocol Based on Frequency Division Multiple Access (FDMA) and Time Division Multiple Access (TDMA) for Radio Frequency Identification (RFID) Readers. *Network*. 2024. vol. 4(2). pp. 217–236.
39. Li D., Nakazato J., Tsukada M. A State-Interactive MAC Layer TDMA Protocol Based on Smart Antennas. *Electronics*. 2024. vol. 13(11).
40. Longla T.T., Shah A.S., Rabie K.M., Li X. S-LEACH-CDMA: Sectoring and CDMA Integration with LEACH for Scalability and Energy Efficiency in Wireless Sensor Networks. *Authorea Preprints*. 2024.
41. Maeng J., Dahouda M.K., Joe I. Optimal power allocation with sectored cells for sum-throughput maximization in wireless-powered communication networks based on hybrid SDMA/NOMA. *Electronics*. 2022. vol. 11(6).
42. Peng M., Li B., Yan Z., Yang M. A spatial group-based multi-user full-duplex OFDMA MAC protocol for the next-generation WLAN. *Sensors*. 2020. vol. 20(14).
43. Ghosh S., Al-Dweik A., Alouini M.S. On the performance of end-to-end cooperative NOMA-based IoT networks with wireless energy harvesting. *IEEE Internet of Things Journal*. 2023. vol. 10(18). pp. 16253–16270.
44. Esmail H., Sun H. Energy Harvesting for TDS-OFDM in NOMA-Based Underwater Communication Systems. *Sensors*. 2022. vol. 22(15). DOI: 10.3390/s22155751.
45. Pandi V.S., Prasina A., Shibu S., Sripriya T. A Novel Downlink Frequency Allocation (DFA) Technique for Enhanced Throughput in 5G and Beyond (B5G) Multi-hop Networks. *Traitement du Signal*. 2024. vol. 41(3). pp. 1345–1354.
46. Yu N., Zhang L., Ren Y. BRS-based robust secure localization algorithm for wireless sensor networks. *International Journal of Distributed Sensor Networks*. 2013. vol. 9(3). DOI: 10.1155/2013/107024.
47. Mestres A., Abadal S., Torrellas J., Alarcon E., Cabellos-Aparicio A. A MAC protocol for reliable broadcast communications in wireless network-on-chip. *Proceedings of the 9th International Workshop on Network on Chip Architectures*. 2016. pp. 21–26. DOI: 10.1145/2994133.2994137.
48. Li X., Xiao F., Tang K., Luo E. Outage performance and energy efficiency optimization of wireless-powered millimeter-wave sensor networks. *EURASIP Journal on Wireless Communications and Networking*. 2024. vol. 2024(1). DOI: 10.1186/s13638-023-02328-2.
49. Gulyamov S., Yusupbekov A., Mirzaev D., Kuziev Z. Algorithms for composing communication protocols of wireless sensor networks with random access. *E3S Web of Conferences*. 2023. vol. 417.
50. Dhabliya D., Soundararajan R., Selvarasu P., Balasubramaniam M.S., Rajawat A.S., Goyal S.B., Raboaca M.S., Mihaltan T.C., Verma C., Suci G. Energy-efficient network protocols and resilient data transmission schemes for wireless sensor Networks – An experimental survey. *Energies*. 2022. vol. 15(23). DOI: 10.3390/en15238883.
51. Thahniyath G., Jayaprasad M. Secure and load balanced routing model for wireless sensor networks. *Journal of King Saud University-Computer and Information Sciences*. 2022. vol. 34(7). pp. 4209–4218.

52. Ndoye E.H.M., Diallo O., Hakem N., Jacquet F., Misson M., Rodrigues J.J. Interference-aware clustering approach improving QoS for linear WSNs using a token-based MAC protocol. *International Journal of Communication Systems*. 2020. vol. 33(11).
53. Nagaraju S., Gudino L.J., Sood N., Chandran J.G., Sreejith V. Multiple token-based neighbor discovery for directional sensor networks. *ETRI Journal*. 2020. vol. 42(3). pp. 351–365.
54. Mundada M.R., Kiran S., Khobanna S., Varsha R.N., George S.A. A study on energy efficient routing protocols in wireless sensor networks. *International Journal of Distributed and Parallel Systems (IJDPs)*. 2012. vol. 3. pp. 311–330.
55. Anees J., Zhang H.C., Lougou B.G., Baig S., Dessie Y.G. Delay aware energy-efficient opportunistic node selection in restricted routing. *Computer Networks*. 2020. vol. 181.
56. Lee D., Attias R., Puri A., Sengupta R., Tripakis S., Varaiya P. A wireless token ring protocol for intelligent transportation systems. *IEEE Intelligent Transportation Systems. Proceedings (ITSC 2001)*. IEEE, 2001. pp. 1152–1157.
57. Hang Z., Bo L., Zhongjiang Y., Mao Y., Xinru L. A multi-token sector antenna neighbor discovery protocol for directional ad hoc networks. *China Communications*. 2024.
58. Maurya S., Gupta V., Jain V.K. Lbrr: Load balanced ring routing protocol for heterogeneous sensor networks with sink mobility. *IEEE wireless communications and networking Conference (WCNC)*. IEEE, 2017. pp. 1–6.
59. Cevik T., Zaim A.H. EETBR: Energy efficient token-based routing for wireless sensor networks. *Turkish Journal of Electrical Engineering and Computer Sciences*. 2013. vol. 21(2). pp. 513–526.
60. Han B., Ran F., Li J., Yan L., Shen H., Li A. A novel adaptive cluster based routing protocol for energy-harvesting wireless sensor networks. *Sensors*. 2022. vol. 22(4).
61. Qureshi K.N., Bashir M.U., Lloret J., Leon A. Optimized cluster-based dynamic energy-aware routing protocol for wireless sensor networks in agriculture precision. *Journal of sensors*. 2020. vol. 2020(1).
62. Hu H., Fan X., Wang C. Efficient cluster-based routing protocol for wireless sensor networks by using collaborative-inspired Harris Hawk optimization and fuzzy logic. *Plos one*. 2024. vol. 19(4).
63. Wang H., Liu K., Wang C., Hu H. Energy-Efficient, Cluster-Based Routing Protocol for Wireless Sensor Networks Using Fuzzy Logic and Quantum Annealing Algorithm. *Sensors*. 2024. vol. 24(13).
64. El Habib Kahla M., Beggas M., Laouid A., Hammoudeh M. A Nature-Inspired Partial Distance-Based Clustering Algorithm. *Journal of Sensor and Actuator Networks*. 2024. vol. 13(4).
65. Sundararajan R.K., Jayaraman G., Arunkumar S., Jeyapandian M., Kaliyaperumal K., Perumal D., Dhulipala V.S. EECAS: Energy Efficient Clustering and Aggregator Node Selection for Wireless Sensor Networks. *Wireless Personal Communications*. 2024. vol. 136. pp. 899–919.
66. Preetha M., Anil Kumar N., Elavarasi K., Vignesh T., Nagaraju V. A Hybrid Clustering Approach Based Q-Leach in TDMA to Optimize QOS-Parameters. *Wireless Personal Communications*. 2022. pp. 1–32.
67. Akila E., Deepa B. An Comparison of Different Cluster Head Selection Techniques for Wireless Sensor Network. *Communications on Applied Nonlinear Analysis*. 2024. vol. 31(5s). pp. 479–486.
68. Tay M., Senturk A. A new energy-aware cluster head selection algorithm for wireless sensor networks. *Wireless Personal Communications*. 2022. vol. 122(3). pp. 2235–2251.

69. Sen S., Sahoo L., Ghosh S.L. Lifetime extension of wireless sensor networks by perceptive selection of cluster head using K-Means and Einstein weighted averaging aggregation operator under uncertainty. *J. Ind Intell.* 2024. vol. 2(1). pp. 54–62.
70. Ahmad R., Wazirali R., Bsoul Q., Abu-Ain T., Abu-Ain W. Feature-selection and mutual-clustering approaches to improve DoS detection and maintain WSNs' lifetime. *Sensors.* 2021. vol. 21(14).
71. Begum B.A., Nandury S.V. Data aggregation protocols for WSN and IoT applications – A comprehensive survey. *Journal of King Saud University-Computer and Information Sciences.* 2023. vol. 35(2). pp. 651–681.
72. Jan S.R.U., Khan R., Jan M.A. An energy-efficient data aggregation approach for cluster-based wireless sensor networks. *Annals of telecommunications.* 2021. vol. 76(5). pp. 321–329.
73. Sharmin S., Ahmedy I., Md Noor R. An energy-efficient data aggregation clustering algorithm for wireless sensor Networks using hybrid PSO. *Energies.* 2023. vol. 16(5).
74. Sreedevi P., Venkateswarlu S. An Efficient Intra-Cluster Data Aggregation and finding the Best Sink location in WSN using EEC-MA-PSOGA approach. *International Journal of Communication Systems.* 2022. vol. 35(8).
75. Khedr A.M., Raj P.P., Al Ali A. An Energy-Efficient Data Acquisition Technique for Hierarchical Cluster-Based Wireless Sensor Networks. *J. Wirel. Mob. Networks Ubiquitous Comput. Dependable Appl.* 2020. vol. 11(3). pp. 70–86.
76. Jawaligi S.S. ACRDA: An adaptive combined relay based dynamic data aggregation technique for wireless sensor networks. *Measurement: Sensors.* 2022. vol. 24.

Павале Сушма П. — профессор, факультет компьютерных наук, Технологический университет Висвесварая-RRС. Область научных интересов: информатика. Число научных публикаций — 5. sushmap9feb@gmail.com; QFH7+497 Джнана Сангама, VTU Главная дорога, 590018, Мачхе, Белагави, Карнатака, Индия; р.т.: +91(0831)249-8225.

Патил Пурнима Дж. — профессор, факультет компьютерных наук, Технологический университет Висвесварая-RRС. Область научных интересов: информатика. Число научных публикаций — 5. poornima_g_patil@yahoo.com; QFH7+497 Джнана Сангама, VTU Главная дорога, 590018, Мачхе, Белагави, Карнатака, Индия; р.т.: +91(0831)249-8225.

C.N. ANH , T.B. THAO , T.B. HUNG , T.T. HUONG , N.V. HUNG
**OPTIMIZING TRANSPORTATION COSTS: ENHANCING
LOGISTICS EFFICIENCY AND RESOURCE UTILIZATION IN A
DYNAMIC ENVIRONMENTS**

Cao Ngoc Anh, Tran Bich Thao, Tran Ba Hung, Trinh Thu Huong, Nguyen Viet Hung. **Optimizing Transportation Costs: Enhancing Logistics Efficiency and Resource Utilization in a Dynamic Environments.**

Abstract. The increasing demand for goods transportation, driven by the expansion of global supply chains and rising customer expectations, underscores the critical need to optimize transportation costs to enhance logistics efficiency. In a rapidly evolving and competitive market, businesses face mounting challenges in managing complex transportation networks, minimizing operational costs, and meeting diverse customer requirements. To address these issues, this paper introduces a solution designed to reduce transportation expenses by optimizing the flow of goods and improving resource utilization. By leveraging advanced optimization techniques and data-driven strategies, the proposed solution identifies inefficiencies, streamlines decision-making, and enhances resource allocation. Initial results demonstrate that this approach not only significantly reduces operational costs but also strengthens the ability of businesses to respond quickly and effectively to fluctuating customer demands, ensuring both cost efficiency and customer satisfaction. However, as the logistics industry continues to grow and transaction volumes increase, transportation scenarios are expected to become more complex, and customer requirements more diverse. This evolving landscape demands further refinement and scalability of the proposed solution to address larger networks, more intricate logistics challenges, and a broader range of customer demands. Future research will prioritize the development of larger-scale models capable of incorporating more variables, improving computational efficiency, and delivering faster, more accurate decision-making to meet the increasing complexity of the logistics sector. Therefore, the proposed solution represents a significant advancement in optimizing transportation costs and improving logistics efficiency. Initial results indicate that this solution can cut down transportation costs by 19.02% to 29.65% and enhance computational efficiency in small- to medium-scale routing tasks (10-20 customers). Despite its potential, more research is required to justify scalability to larger datasets. Hence, our approach provides a solid foundation for logistics optimization, with clear prospects for expansion and adaptation in real-world contexts.

Keywords: vehicle routing problem (VRP), linear programming (LP), ant colony optimization (ACO), integer linear programming (ILP), DBSCAN, genetic algorithms (GA).

1. Introduction. The Vehicle Routing Problem (VRP) is one of the most prominent combinatorial optimization problems, with wide-ranging applications in logistics, supply chain management, and transportation [1–3]. The main objective of VRP is to determine the optimal routes for a fleet of vehicles to serve a group of customers while adhering to constraints such as vehicle capacity limits, ensuring each customer is visited once, and requiring vehicles to start and return to a depot. As an NP-hard problem, the complexity of VRP grows significantly with the problem size. This makes traditional optimization methods inefficient in terms of computational time and resources

when addressing large-scale VRP instances [4, 5]. This paper mainly focuses on the optimization of transportation costs in large-scale VRP scenarios with extremely non-uniform customer spatial distributions and spatial outliers. Such unequal distributions are frequently too difficult for traditional VRP techniques to handle, which results in inefficient routing, greater transportation costs, and more computational burdens.

One of the major challenges in VRP lies in handling customer data that is unevenly distributed across large geographic areas. Traditional methods often struggle to optimize routes in such scenarios, leading to high transportation costs and extended computation times. The Density-Based Spatial Clustering of Applications with Noise (DBSCAN) algorithm has demonstrated outstanding performance in clustering data based on density, particularly in cases where customer distributions are non-uniform. A key advantage of DBSCAN is its ability to automatically determine the number of clusters without requiring pre-defined parameters, as is necessary for other clustering algorithms like K-Means [6–8]. Furthermore, DBSCAN can detect and process outliers – customers located far from densely populated clusters – thereby mitigating their potential negative impact on overall routing and cost optimization [9].

To address this issue, clustering techniques, such as the Density-Based Spatial Clustering of Applications with Noise (DBSCAN) algorithm, have been widely adopted. DBSCAN is particularly effective in identifying clusters of customers based on density while also detecting outliers [10–12]. However, while DBSCAN can isolate these outliers, their treatment remains a significant challenge in logistics optimization. If not managed properly, outliers can lead to disproportionately high transportation costs, as vehicles may need to travel long distances for a single delivery. Future advancements in VRP optimization must therefore incorporate robust strategies to address outliers, such as integrating heuristic or metaheuristic methods (e.g., Ant Colony Optimization or Genetic Algorithms) to design dedicated routes, or dynamically assigning outliers to neighboring clusters based on cost-impact analysis.

In this study, we propose a novel approach that combines DBSCAN and integer linear programming (ILP) models to address VRP effectively. The core idea involves using DBSCAN to cluster customers based on density and geographic proximity. This clustering process divides a large-scale VRP into smaller, more manageable sub-problems, significantly reducing computational complexity. After clustering, each customer group is treated as an independent VRP instance, which is solved using an ILP model. This approach enables cost optimization for each cluster while minimizing the overall computation time, especially in large-scale logistics systems [13–15].

The novelty of this method lies in its flexible integration of clustering and optimization. DBSCAN not only clusters customers effectively but also reduces the dependence on pre-defined parameters such as the number of clusters, making the method more adaptable to complex real-world situations. Moreover, by identifying and processing outliers separately, the approach ensures that route optimization is not adversely affected by customers located far from central areas. Once the clustering process is completed, the customer groups are fed into an ILP model to solve the VRP for each cluster, ensuring accurate and efficient solutions [16–18].

The methodology proposed in this study aims to enhance efficiency and flexibility in addressing the Vehicle Routing Problem (VRP), particularly in large-scale, real-world scenarios with non-uniform customer distributions. Unlike conventional approaches that treat the VRP as a single, monolithic problem, the proposed framework introduces a two-step process to reduce computational complexity and improve scalability. First, the DBSCAN clustering algorithm is employed to partition customers into distinct groups based on geographic proximity and density, transforming the VRP into smaller, independent sub-problems. Each sub-problem is then optimized using Integer Linear Programming (ILP) to minimize costs within individual clusters. To address the challenges posed by customer outliers, these are managed separately to minimize their impact on the overall solution. As illustrated in Figure 1(a), traditional approaches struggle with large-scale instances, uneven customer distributions, and outliers, leading to high computational costs and limited flexibility. In contrast, as shown in Figure 1(b), the proposed methodology leverages clustering and sub-problem optimization to significantly reduce computational demands, enhance cost efficiency, and demonstrate robust scalability, making it particularly well-suited for real-world logistics systems.

This approach not only reduces computational time by breaking down the problem into smaller parts but also opens up possibilities for integration with modern algorithms such as Genetic Algorithms (GA) or Ant Colony Optimization (ACO) to tackle larger or more complex VRP instances. Additionally, the approach can be extended to address VRP variations such as Multi-Depot VRP, VRP with Time Windows (VRPTW), or Green VRP, where environmental considerations are incorporated [7, 19, 20]. With these advantages, our approach promises to provide an effective and practical solution for addressing VRPs in modern logistics systems.

The remainder of this paper is organized as follows: In Section 2, the existing state-of-the-art methodologies are thoroughly reviewed and discussed. In Section 3, the proposed algorithm is introduced and its details are carefully elaborated upon. Following this, in Section 4, an evaluation of the algorithm is

conducted using appropriate metrics and benchmarks. Finally, the conclusions of the study are summarized and presented in Section 5, where the key findings and implications of the research are highlighted.




Fig. 1. Cluster-Based Optimization for Large-Scale Vehicle Routing Problems

2. Related work. The Vehicle Routing Problem (VRP) has been extensively studied due to its critical role in logistics, supply chain management, and transportation. Over the years, various approaches have been developed to address its complexity, especially for large-scale and real-world scenarios. This section reviews recent works (from 2022 onward) that focus on clustering techniques, optimization models, and hybrid methodologies to solve VRP and its variations.

One of the popular directions in VRP research involves the application of clustering techniques to divide large-scale problems into smaller, more manageable sub-problems. For instance, an enhanced DBSCAN (Density-Based Spatial Clustering of Applications with Noise) algorithm for VRP

with heterogeneous fleets has been proposed, clustering customers based on geographic proximity and handling outliers separately, which significantly improves the efficiency of the optimization process [21–24]. Similarly, hybrid clustering algorithms have been demonstrated to solve VRP with time windows, showing that clustering reduces computational complexity by breaking the problem into smaller sub-problems, which can then be solved independently [9, 25, 26].

DBSCAN has gained attention for its ability to automatically determine the number of clusters based on data density, unlike traditional methods like K-Means which require predefined parameters. This feature makes DBSCAN particularly suitable for real-world logistics systems where customer distributions are often non-uniform. Research highlights the effectiveness of clustering techniques, including DBSCAN, in addressing Green VRP, where the goal is to minimize both transportation costs and environmental impact [7, 21, 27]. These studies underscore the potential of clustering to optimize routes while considering sustainability metrics. Another key aspect of VRP research is the integration of clustering with optimization models. Hybrid approaches that combine clustering with genetic algorithms have been explored to solve multi-depot VRP with time windows. These methods improve routing efficiency by leveraging the strengths of both clustering and metaheuristic optimization [26]. Similarly, the combination of clustering with reinforcement learning has been used to tackle large-scale VRPs. This method involves clustering customers first and then using reinforcement learning to optimize routes within each cluster, achieving significant reductions in computational time and costs [28].

Integer Linear Programming (ILP) models have also been widely employed to solve VRP sub-problems after clustering. An ILP-based framework has been presented that incorporates constraints like vehicle capacity, customer service requirements, and depot return conditions. It has been emphasized that clustering before applying ILP not only reduces problem size but also enhances the overall solution quality [29]. This aligns with findings from reviews of various clustering and optimization techniques, concluding that combining DBSCAN with ILP provides a robust framework for solving VRPs in large-scale logistics systems [5, 30].

Recent studies have also focused on handling VRP variations, such as VRP with Time Windows (VRPTW) and Multi-Depot VRP. A hybrid approach integrating Ant Colony Optimization (ACO) with clustering techniques has been proposed to solve capacitated VRPs. It has been shown that clustering customers before applying ACO significantly improves its performance, especially in problems with capacity and time constraints [31]. Similarly, research

addressing VRP with multiple depots partitions customers into clusters based on depot proximity, followed by route optimization using genetic algorithms, indicating substantial improvements in both computational efficiency and route quality [26].

The ability to handle outliers effectively is another important consideration in VRP research. Outliers, or customers located far from densely populated areas, can significantly impact routing efficiency. Research emphasizes the need to treat outliers separately to minimize their negative effects on overall routing and transportation costs [6]. By isolating and optimizing routes for outliers independently, these approaches ensure that the main clusters remain unaffected, leading to better overall solutions.

In addition to these methodological advancements, Green VRP (G-VRP) has emerged as a critical area of research in recent years [32–35]. Studies have explored the integration of clustering and optimization techniques to minimize fuel consumption and greenhouse gas emissions in logistics systems. The findings demonstrate that clustering techniques like DBSCAN can significantly contribute to reducing environmental impact while maintaining high efficiency in route planning [36].

In summary, recent studies highlight the growing importance of combining clustering and optimization techniques to solve VRP and its variations. Clustering algorithms, particularly DBSCAN, have proven effective in handling non-uniform customer distributions and reducing computational complexity. Prior studies have demonstrated that, as long as clusters are balanced and geographically coherent, clustering-based routing strategies, especially those that use DBSCAN or other density-based techniques, remain computationally efficient for problem sizes up to several hundred customers [37, 38]. When integrated with optimization models like ILP or metaheuristic algorithms, these methods offer robust solutions for large-scale and real-world VRP instances. The ability to handle VRP variations, such as VRPTW, Multi-Depot VRP, and Green VRP, further underscores the versatility of these approaches. These findings lay the foundation for the proposed method, which leverages DBSCAN and ILP to address the challenges of large-scale VRPs more efficiently.

Although digital twin-based solutions offer full-scale simulations of logistics operations, their adaptability for real-time decision-making is limited by their frequent need for substantial system modeling and high processing power. The approach proposed in this paper, on the other hand, emphasizes computational efficiency by utilizing independent route optimization and clustering without recreating the dynamics of the entire system. Due to this distinction, which allows for faster response to dynamic logistical environments,

the method is especially well-suited for large-scale real-world applications where quick re-optimization is required.

3. Proposed Model. The proposed model is designed to address the challenges associated with optimizing transportation costs in large-scale logistics systems, particularly those involving uneven customer distributions and significant computational complexity. By leveraging a two-step framework, the model integrates Density-Based Spatial Clustering of Applications with Noise (DBSCAN) for customer clustering and Integer Linear Programming (ILP) for route optimization within each cluster. This approach effectively divides the Vehicle Routing Problem (VRP) into manageable sub-problems, significantly reducing computational demands while maintaining the accuracy and cost-efficiency of the solution.

The novelty of the proposed model lies in its ability to flexibly adapt to real-world scenarios. DBSCAN not only identifies clusters of customers based on geographic proximity and density but also detects outliers – customers located far from densely populated regions. These outliers, if untreated, can disrupt overall optimization and inflate costs. The model addresses this by allowing for the integration of additional strategies, such as heuristic or metaheuristic methods, to manage outliers effectively.

Once customers are grouped into clusters by DBSCAN, the ILP model is applied to each cluster to determine the optimal routes while respecting vehicle capacity constraints and minimizing travel costs. This modular approach ensures that the scalability of the solution is enhanced, making it well-suited for large-scale and dynamic logistics environments. Furthermore, the framework provides a strong foundation for extending the methodology to handle variations of VRP, such as Multi-Depot VRP, VRP with Time Windows (VRPTW), and Green VRP, thereby addressing both operational and environmental considerations.

In the following sections, we delve into the detailed components of the proposed model, including the problem description, mathematical formulation, and algorithmic implementation. These sections outline the technical underpinnings and demonstrate how the model achieves an efficient balance between computational feasibility and solution quality.

3.1. Problem Description. The Vehicle Routing Problem (VRP) is a classic optimization problem in logistics and transportation. It involves designing optimal routes for a fleet of vehicles to deliver goods to a set of customers. Each customer has a specific demand, and each vehicle has a limited capacity. The goal is to minimize the total travel cost while ensuring that all operational constraints are satisfied.

In this problem, the depot serves as the starting and ending point for all vehicle routes. It is represented as node 0 in the network. Each route begins at the depot, serves a subset of customers, and then returns to the depot. The customers are represented as nodes in the network, and there are n customers in total. Each customer is associated with a specific demand $q[i]$ that must be met. Importantly, each customer must be visited exactly once by one vehicle, and no customer can be skipped.

The vehicles used in this problem have a maximum capacity of Q , which limits the total demand that can be served on a single route. This capacity constraint ensures that the total demand of the customers served on a single route does not exceed the vehicle's capacity. All vehicles are assumed to be homogeneous, meaning they have the same capacity and operational characteristics.

The objective of the VRP is to minimize the total travel cost, which is calculated as the sum of the distances traveled by all vehicles. This travel cost is influenced by the sequence in which customers are visited, as well as the assignment of customers to specific vehicles.

One of the main challenges of solving the VRP is its computational complexity. As the number of customers increases, the number of possible routes grows exponentially, making the problem increasingly difficult to solve. To address this challenge, the problem is simplified using DBSCAN clustering, a density-based clustering algorithm. DBSCAN groups customers into clusters based on their geographic proximity. Each cluster is then treated as a smaller, independent VRP instance. This approach significantly reduces the computational complexity while ensuring that the overall solution remains feasible and cost-effective. In addition to the issues discussed, another significant challenge in optimizing logistics systems is the efficient management of outliers – customers located far from densely populated clusters. While the DBSCAN algorithm effectively identifies such outliers during the clustering process, the manner in which they are handled greatly influences the overall solution quality and cost. Outliers can result in inefficient routes, as they may require vehicles to travel long distances for a single delivery. To address this challenge, future enhancements could incorporate specialized heuristic or metaheuristic methods, such as Ant Colony Optimization (ACO) or Genetic Algorithms (GA), to design dedicated routes for outliers. Furthermore, integrating outlier-handling strategies into the main optimization framework – such as assigning outliers to neighboring clusters based on cost-impact analysis or serving them with dedicated vehicles – can help reduce their negative impact on total travel costs and computational efficiency. By explicitly addressing the issue of outliers, the proposed method can further improve its scalability and

robustness, ensuring its effectiveness even in scenarios with uneven customer distributions.

By using clustering, the problem is broken down into manageable subproblems, making it possible to solve larger instances of the VRP more efficiently while still minimizing the total travel cost.

On the other hand, Figure 2 illustrates the architecture of a generalized flowchart designed to optimize the fleet planning system, which consists of three core components. First, the Customer Data Collection component gathers essential input data, including customer addresses and demand requirements. This data is then processed by the Fleet Planning System, which optimizes vehicle allocation and route planning to efficiently meet customer demands while minimizing operational costs. Finally, the system generates a Report that provides detailed information, including the total number of vehicles required, optimized routes for each vehicle, a breakdown of customers assigned to each route, and route-specific details such as total distance traveled. This architecture streamlines operations, enhances decision-making processes, and ensures the effective allocation of resources to meet customer needs.




Fig. 2. Framework for the Proposed System Architecture

The **Compute Distance Matrix** is designed to calculate the distance matrix C for a given set of coordinates, which include the depot and customer locations. The input is a list of coordinates, represented as pairs (x, y) , denoted as

$$\text{coords} = \{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\}. \quad (1)$$

The output is a matrix $C = [c_{ij}]$, where each element c_{ij} represents the Euclidean distance between two points i and j . The algorithm iterates over all points i and, for each point i , iterates over all points j to compute the Euclidean distance using the formula:

$$c_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}. \quad (2)$$

The calculated distances are stored in the matrix C , which is then returned as the result. This algorithm is commonly applied in optimization problems, such as the Traveling Salesman Problem (TSP) or Vehicle Routing Problem (VRP), where distance calculations between locations are essential.

The algorithm 1 **Cluster Customers Using DBSCAN** is used to group customer locations into clusters based on their spatial proximity, using the DBSCAN clustering method. The input consists of a set of customer coordinates $\text{coords} = \{(x_1, y_1), \dots, (x_n, y_n)\}$ (excluding the depot), along with two key parameters: ϵ , which defines the radius for neighborhood calculation, and min_samples , which specifies the minimum number of points required to form a cluster. The algorithm applies the DBSCAN method to the input coordinates, assigning each customer a cluster ID c_i . If a customer does not belong to any cluster, it is marked as noise with a cluster ID of -1 . Customers with valid cluster IDs (i.e., $c_i \neq -1$) are added to their respective clusters.

Algorithm 1. Cluster Customers Using DBSCAN

– **coords** = $[(x_1, y_1), \dots, (x_n, y_n)]$: Customer coordinates (excluding the depot).
 – ϵ : Radius parameter for DBSCAN.
 – *min_samples*: Minimum number of points for a cluster.
 Cluster assignments **clusters** for each customer.
 Apply DBSCAN to the customer coordinates.
 customer $i \in \{1, 2, \dots, n\}$ Assign a cluster ID c_i to customer i (or -1 if it is noise).
 Add customer i to the corresponding cluster if $c_i \neq -1$.
return clusters.

Finally, the algorithm returns the list of clusters, where each cluster groups customers that are spatially close to each other. This approach is particularly useful in applications like logistics and delivery optimization, as it can identify clusters with arbitrary shapes and detect outliers effectively.

In addition, the algorithm 2 solves this optimization problem. If a feasible solution is found, the optimal objective value C'_k is computed and returned as the result. Otherwise, the algorithm outputs “No solution found for Cluster k ” and returns ∞ . This approach is commonly used in Vehicle Routing Problems (VRP) to minimize travel costs while satisfying delivery constraints for a specific cluster of customers.

Algorithm 2. Solve VRP for a Single Cluster

- Cluster k : Set of customer nodes cluster_k .
- Q : Maximum vehicle capacity.
- $\mathbf{q} = [q_0, q_1, \dots, q_n]$: Customer demands.
- Distance matrix $\mathbf{C} = [c_{ij}]$.

Cost C_k of the optimal route for cluster k .

Define the set of nodes for the cluster:

$$\text{nodes}_k \leftarrow \{0\} \cup \text{cluster}_k \cup \{n+1\},$$

where 0 is the depot and $n+1$ is the virtual depot.

Decision Variables:

- x_{ij} : Binary variable indicating travel from i to j .
- u_i : Load at node i .

Objective Function: Minimize total travel cost:

$$\min \sum_{i \in \text{nodes}_k} \sum_{j \in \text{nodes}_k, i \neq j} c_{ij} \cdot x_{ij}.$$

Constraints:

- Each customer is visited and departed exactly once.
- Ensure load balancing and respect vehicle capacity limits.
- Start at the depot and end at the virtual depot.

Solve the optimization problem using a solver (e.g., Gurobi).

if a feasible solution is found **then** Compute $C_k \leftarrow$ Optimal objective value.

return C_k .

else Print: "No solution found for Cluster k ."

return ∞ .

On the other hand, the algorithm 3 **Clustering and Solving VRP** is designed to solve the Vehicle Routing Problem (VRP) by combining

clustering and route optimization. The input includes the number of customers n , the vehicle's maximum capacity Q , customer demands $q = [q_0, q_1, \dots, q_n]$, and the coordinates of the depot and customers $\text{coords} = \{(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)\}$. Additionally, the parameters ϵ (the radius for DBSCAN) and min_samples (the minimum number of points required for clustering) are provided.

Algorithm 3. Clustering and Solving VRP

- n : Number of customers.
- Q : Maximum vehicle capacity.
- $\mathbf{q} = [q_0, q_1, \dots, q_n]$: Customer demands.
- $\text{coords} = [(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)]$: Coordinates of depot and customers.
- ϵ : Radius parameter for DBSCAN.
- min_samples : Minimum number of points for DBSCAN.

Total cost C_{total} and optimal routes.

Step 1: Compute Distance Matrix.

Call **Formula 2** to compute C .

Step 2: Cluster Customers Using DBSCAN.

Call **Algorithm 1** to compute clusters.

Step 3: Solve VRP for Each Cluster.

Initialize total cost: $C_{\text{total}} \leftarrow 0$.

cluster k in clusters Call **Algorithm 2** for cluster k .

if a feasible solution is found **then** Update total cost: $C_{\text{total}} \leftarrow C_{\text{total}} + C_k$.

return C_{total} .

The algorithm computes the total cost C_{total} and the optimal routes using the following steps:

Step 1: Compute Distance Matrix. Call Algorithm 1 to calculate the distance matrix C , which represents pairwise distances between customers and the depot.

Step 2: Cluster Customers Using DBSCAN. Call Algorithm 2 to group customers into clusters based on their spatial proximity.

Step 3: Solve VRP for Each Cluster. For each cluster k , call Algorithm 3 to determine the optimal route and cost C_k . Initialize the total cost as $C_{\text{total}} = 0$. For every cluster, if a feasible solution is found, update the total cost as $C_{\text{total}} \leftarrow C_{\text{total}} + C_k$. If no feasible solution is found for a cluster, the algorithm terminates for that cluster.

Finally, the algorithm 3 returns the total cost C_{total} , which represents the minimum travel cost for all clusters. This approach effectively combines

clustering (using DBSCAN) and routing (using VRP optimization) to solve complex logistics problems efficiently.

3.2. Mathematical Formulation. The Vehicle Routing Problem (VRP) is mathematically formulated as a **Mixed Integer Linear Programming (MILP)** problem, which involves defining sets, parameters, decision variables, an objective function, and constraints. The following provides a detailed explanation of the mathematical model.

Sets. The problem involves the following sets:

- N – the set of customer nodes, indexed as $1, 2, \dots, n$.
- V – the set of all nodes, including the depot (0) and the artificial end node $(n + 1)$, i.e., $V = \{0, 1, 2, \dots, n, n + 1\}$.
- C – the set of clusters identified by the DBSCAN clustering algorithm, where each cluster contains a subset of customers.

Parameters. The parameters used in the model are:

- $c[i][j]$ – the distance or cost of traveling from node i to node j .
- $q[i]$ – the demand of customer i . For the depot, $q[0] = 0$.
- Q – the maximum capacity of each vehicle. This parameter ensures the vehicle cannot exceed its load limit.

Decision Variables. Two decision variables are defined in this model:

- $x[i][j]$ – a binary variable that indicates whether a vehicle travels directly from node i to node j . It is defined as:

$$x[i][j] = \begin{cases} 1 & \text{if a vehicle travels from node } i \text{ to node } j, \\ 0 & \text{otherwise.} \end{cases} \quad (3)$$

- $u[i]$ – a continuous variable representing the load of a vehicle after visiting node i . This variable ensures that the vehicle's capacity is respected throughout the route.

Objective Function. The objective of the VRP is to minimize the total travel cost. This cost is calculated as the sum of the distances between all pairs of nodes i and j , weighted by the decision variable $x[i][j]$. The objective function is expressed as:

$$\text{Minimize } Z = \sum_{i \in V} \sum_{\substack{j \in V \\ i \neq j}} c[i][j] \cdot x[i][j]. \quad (4)$$

Constraints. The model includes several constraints to ensure the feasibility of the solution.

Customer Visit Constraints. Each customer must be visited exactly once by one vehicle. This is enforced using the following constraints:

$$\sum_{\substack{i \in V \\ i \neq j}} x[i][j] = 1, \quad \forall j \in N. \quad (5)$$

$$\sum_{\substack{j \in V \\ i \neq j}} x[i][j] = 1, \quad \forall i \in N. \quad (6)$$

The first constraint ensures that exactly one vehicle arrives at each customer, while the second ensures that exactly one vehicle leaves each customer.

Depot Flow Constraints. Vehicles must start and end their routes at the depot. These constraints are given by:

$$\sum_{j \in N} x[0][j] = 1. \quad (7)$$

$$\sum_{i \in N} x[i][n+1] = 1. \quad (8)$$

The first constraint ensures that exactly one vehicle departs from the depot, while the second ensures that exactly one vehicle returns to the depot.

Subtour Elimination Constraints. To prevent invalid routes (subtours that do not include the depot), the following constraints are introduced:

$$u[j] \geq u[i] + q[j] - Q \cdot (1 - x[i][j]), \quad \forall i, j \in N, i \neq j. \quad (9)$$

If $x[i][j] = 1$, meaning a vehicle travels from node i to node j , the load at node j must be at least the load at i plus the demand at j . Otherwise, if $x[i][j] = 0$, the constraint is relaxed.

Vehicle Capacity Constraints. The load at each node must respect the vehicle's capacity. The following constraints ensure that the load at any node does not exceed the vehicle's capacity:

$$q[i] \leq u[i] \leq Q, \quad \forall i \in N. \quad (10)$$

Binary Decision Constraints. The decision variables $x[i][j]$ are binary, meaning they can only take values of 0 or 1:

$$x[i][j] \in \{0, 1\}, \quad \forall i, j \in V. \quad (11)$$

Explanation of the Model. This model captures the essential components of the VRP and ensures that all operational constraints are satisfied. The **objective function** minimizes the total cost, while the **constraints** ensure that vehicles respect their capacity, visit all customers exactly once, and prevent the creation of invalid routes. The **subtour elimination constraints** are particularly important to ensure that all routes are connected and include the depot.

By solving this mathematical model for a given cluster of customers, an optimal or near-optimal route can be obtained for that cluster. The total solution is then constructed by solving the VRP for all clusters and combining their results. This approach balances computational efficiency and solution quality.

4. Performance Evaluation

4.1. Experimental Settings. The approach in this study involves a fleet of vehicles starting and ending at a single depot while serving a set of customers with specific demands. Each customer is associated with a demand value (q), and the vehicles have a maximum load capacity (Q). The distances between customers were calculated as a cost matrix (c) using the Euclidean distance derived from their coordinates. This setup ensures that all necessary data for modeling the VRP is precomputed and ready for optimization.

To improve computational efficiency, customers were grouped into clusters using the DBSCAN algorithm from the sklearn library. DBSCAN was applied to the coordinates of the customers, excluding the depot, with a radius (epsilon) of 5 and a minimum sample size (*min_samples*) of 2, and customers change, Figure 3 is an illustration of 20 customers. This clustering approach organizes customers into manageable groups based on their spatial proximity, reducing the complexity of solving the VRP for large datasets. Outliers identified by DBSCAN were excluded from further optimization. For each identified cluster, a separate VRP was formulated and solved using the Gurobi optimization solver. Binary decision variables ($x[i, j]$) were used to represent whether a vehicle travels directly between two nodes, while continuous variables ($u[i]$) tracked the load at each node. Constraints ensured that each customer was served exactly once, vehicle load limits were respected, and all routes started and ended at the depot. This modular approach allows solving smaller subproblems, which are computationally more efficient.




Fig. 3. An example of customer data (20 customers)

The objective function aimed to minimize the total travel cost across all routes within each cluster, defined as the sum of distances between nodes. The optimization results for all clusters were combined to calculate the overall cost. If no feasible solution was found for a particular cluster, this was reported. This clustering-based solution strategy provides an effective way to address large-scale VRP instances by dividing the problem into smaller, more tractable subproblems.

The testing process was conducted using the Python programming language. The program was executed on Gurobi Optimizer version 12.0.0 (build v12.0.0rc1) running on a Windows 10 operating system (version 19045.2). The hardware environment consisted of an Intel® Core™ i7-6500U CPU operating at 2.50 GHz, equipped with instruction sets [SSE2, AVX, AVX2]. The system featured 2 physical cores and 4 logical processors, with a maximum utilization of 4 threads. For further details on the Gurobi software, refer to Gurobi Optimization¹.

4.2. Experimental Results. In this section, we present a detailed analysis and comparison of the empirical results obtained from our approach against those achieved by other established methods. To ensure a comprehensive evaluation, we consider multiple performance metrics, including solution

¹<https://www.gurobi.com/>

quality, computational efficiency, and scalability. Our approach is benchmarked against three well-known approaches commonly used in the field:

- Integer Linear Programming (ILP), outlined in [39], which targets freight issues faced by Vietnamese logistics companies. By modeling the Vehicle Routing Problem (VRP) for small-scale logistics companies, this approach accounts for challenges such as traffic congestion, poor infrastructure, and limited technology use. The ILP model produced optimal solutions with small additional costs, highlighting its practicality and effectiveness for addressing real-world problems in the Vietnamese logistics sector.

- Genetic Algorithms (GAs), as described in [1], which solve the Vehicle Routing Problem (VRP) by encoding the problem into chromosomes, applying crossover and mutation operators to generate new solutions, and using fitness functions to select the best candidates. This method iteratively evolves solutions to achieve optimal or near-optimal routes, reducing costs and optimizing resources, with proven applicability in real-world transportation and logistics.

- Hybrid Genetic Algorithm-Solomon Insertion Heuristic (HGA-SIH), introduced in [40], which addresses the Vehicle Routing Problem with Time Windows (VRPTW). This approach combines a Hybrid Genetic Algorithm (HGA) with the effective Solomon Insertion Heuristic (SIH) to optimize vehicle routes. Tested on Solomon's benchmark instances, HGA-SIH delivered Best-Known Solutions (BKS) for 11 cases and improved one BKS, consistently achieving results comparable to or better than state-of-the-art algorithms. It effectively minimizes travel distance and manages vehicle usage, demonstrating adaptability and efficiency for diverse VRPTW scenarios.

By analyzing these results, we aim to highlight the strengths and potential limitations of our approach. This comparison not only demonstrates the effectiveness of the approach in solving the problem but also provides insights into how it performs relative to existing methods in terms of achieving optimal or near-optimal solutions within acceptable computational times. The evaluation emphasizes the practical applicability of our approach in addressing complex real-world scenarios, particularly in transportation and logistics optimization.

In Figure 4(a), where the vehicle load capacity is set to $Q = 5$, our approach demonstrates a clear advantage over the other methods (VRPA, VRPTW, and GA) in minimizing costs across all customer scenarios (10, 15, and 20). As the number of customers increases, the cost difference between our approach and the others becomes more significant. This highlights the robustness of our approach to handling larger customer demands, even with limited vehicle capacity.

For Figure 4(b), with a vehicle load capacity of $Q = 10$, a similar trend is observed. Our approach consistently achieves the lowest costs, maintaining its efficiency regardless of the number of customers. In contrast, the GA (Genetic Algorithm) method produces the highest costs, particularly when the customer count reaches 20, indicating its limitations in managing larger and more complex routing problems. The VRPA and VRPTW methods perform moderately but remain less effective compared to our approach.



a) Cost Comparison of Methods for Vehicle Routing Problem with $Q = 5$




b) Cost Comparison of Methods for Vehicle Routing Problem with $Q = 10$


Fig. 4. Cost Comparison of Methods for Vehicle Routing Problem Under Different Vehicle Load Capacities (with $Q = 5$ and $Q = 10$)

In Figure 5, the results depicted in both charts indicate that our approach consistently outperforms the other methods (VRPA, VRPTW, and GA) in

terms of cost minimization across different scenarios of customer numbers (10, 15, and 20) and vehicle load capacities ($Q = 15$ and $Q = 20$). Specifically, our approach achieves significantly lower costs compared to the other approaches, particularly as the number of customers increases, demonstrating its scalability and efficiency.



a) Cost Comparison of Methods for Vehicle Routing Problem with $Q = 15$



b) Cost Comparison of Methods for Vehicle Routing Problem with $Q = 20$

Fig. 5. Cost Comparison of Methods for Vehicle Routing Problem Under Different Vehicle Load Capacities (with $Q = 15$ and $Q = 20$)

The GA (Genetic Algorithm) method, on the other hand, incurs the highest costs among the compared methods, especially when dealing with a larger number of customers. This trend is evident in both cases where $Q = 15$ and $Q = 20$, suggesting that GA may not be as effective in handling complex and large-scale vehicle routing problems. The VRPA and VRPTW methods

show relatively stable performance, with costs increasing moderately as the number of customers grows. However, their costs are consistently higher than our approach, indicating a less optimized solution.

Overall, the analysis of both figures highlights that our approach, with its ability to significantly reduce costs, stands out as the most efficient solution. Its adaptability to varying vehicle load capacities and customer demands further emphasizes its robustness.

Although Genetic Algorithms (GAs) can produce high-quality solutions, they are fundamentally heuristic and depend on stochastic processes, for example, selection, crossover, and mutation. Computational time and hyperparameter adjustment frequently influence on their performance. In order to replicate real-world circumstances in logistics planning, when quick decisions are essential, GA was implemented in our studies with the same time constraints as other methods. In these circumstances, GA was found to converge more frequently to poor solutions, particularly when outliers are present or the datasets have uneven spatial distributions.

In contrast, our approach decomposes the VRP into more manageable and homogeneous subproblems using clustering techniques to reduce computational complexity. This structure guarantees that outliers do not disproportionately impact on the global solution and enables the ILP solver to function more efficiently inside each cluster. Consequently, given practical time and data constraints, our approach performs better in terms of cost reduction and computing efficiency.

We admit that GA may be able to match or surpass the quality of our approach with much more runtime and appropriate tuning. However, our hybrid clustering-optimization approach is more dependable in practice due to the requirement for consistent, scalable, and explicable performance in actual logistical scenarios. By excelling under strict vehicle load constraints ($Q = 5$ and $Q = 10$), our approach demonstrates superior performance compared to other approaches. Its remarkable ability to handle complex scenarios while maintaining low costs solidifies its suitability for practical applications that demand both optimization and flexibility.

Our approach was tested using synthetic datasets of up to 20 customers. This choice indicates computational constraints at this stage of development, however, it allows us to compare the relative performance of ILP, GA, and our proposed DBSCAN-ILP framework. We acknowledge that further testing on greater, more complex routing situations is necessary to adequately assess scalability, even if findings consistently demonstrate cost and time improvements in smaller datasets.

5. Conclusions. In the context of the increasing demand for goods transportation, both in terms of scale and complexity, optimizing transportation costs plays a crucial role in enhancing the efficiency of logistics operations and better meeting customer requirements. In this paper, we have proposed a solution aimed at improving transportation costs by focusing on optimizing the flow of goods and enhancing resource utilization. The initial results demonstrate that applying this solution not only reduces operational costs but also improves the ability to respond quickly and effectively to the diverse needs of customers.

However, with the continuous growth of the market and the increasing volume of goods transactions, customer requirements are expected to become more demanding. This necessitates that the current solutions be further refined and expanded to better address future challenges and also highlights the necessity of incorporating metaheuristic methods and adaptive clustering strategies to preserve computational efficiency at larger scales. The proposed DBSCAN-ILP framework remains most effective when cluster sizes are relatively balanced and the number of outliers is low, making it well-suited for moderately sized logistics problems. Even though the suggested clustering-optimization approach performs well in small-scale synthetic experiments, more testing on bigger datasets is necessary. As problem size increases, cluster imbalance and growing ILP subproblem sizes may reduce the computational efficiency of the solution. We predict that adaptive cluster scaling and integration with metaheuristic algorithms may become crucial for computing efficiency when the number of customers exceeds several hundred. Future study should focus on these improvements as well as the anticipated validation using real-world benchmarks such as Solomon VRP datasets.

Future studies will concentrate on a number of aspects. Firstly, in order to evaluate performance in real-world scenarios, benchmark datasets such as Solomon Benchmark problems will be implemented for real-world validation. Secondly, in order to handle outliers better and enhance scalability, integration with sophisticated metaheuristic techniques like Ant Colony Optimization (ACO) and Genetic Algorithms (GA) will be investigated. Lastly, more research will look into real-time re-optimization and dynamic clustering to adjust to constantly shifting customer needs in extremely dynamic logistical settings. To further validate the scalability of our method, future work will also include comparative runtime evaluations with hybrid and metaheuristic frameworks using larger, more varied datasets.

In general, the solution proposed in this paper represents an important step toward optimizing transportation costs in the context of a rapidly evolving market. We believe that with further enhancements and expansions in the

future, this solution has the potential to become a valuable tool for businesses to tackle the challenges of modern logistics.

References

1. Mageswari M.N. Vehicle routing problem (vrp) using genetic algorithm. *Science*. 2024. vol. 9. no. 3. pp. 1–3.
2. Wang Q., Peng S., Liu S. Optimization of electric vehicle routing problem using tabu search. *Chinese Control and Decision Conference (CCDC)*. IEEE, 2020. pp. 2220–2224.
3. Zhang Q., Wu L., Li J. Application of Improved Scatter Search Algorithm to Reverse Logistics VRP Problem. *IEEE 5th International Conference on Power, Intelligent Computing and Systems (ICPICS)*. IEEE, 2023. pp. 283–288.
4. Alolaiwy M., Hawsawi T., Zohdy M., Kaur A., Louis S. Multiobjective Routing Optimization in Electric and Flying Vehicles: A Genetic Algorithm Perspective. *Applied Sciences*. 2023. vol. 13. no. 18.
5. Ni Q., Tang Y. A Bibliometric Visualized Analysis and Classification of Vehicle Routing Problem Research. *Sustainability*. 2023. vol. 15. no. 9.
6. Kim B.S., Mozhehi A., Wang Y., Sun S., Wang X. Clustering Based Enhanced Ant Colony Optimization for Multi-Trip Vehicle Routing Problem with Heterogeneous Fleet and Time Windows: An Industrial Case Study. *Proceedings of the 17th ACM SIGSPATIAL International Workshop on Computational Transportation Science GenAI and Smart Mobility Session*. 2024. pp. 46–55.
7. Gaon T., Gabay Y., Weiss Cohen M. Optimizing electric vehicle routing efficiency using k-means clustering and genetic algorithms. *Future Internet*. 2025. vol. 17. no. 3.
8. Gao Y., Wu H., Wang W. A hybrid ant colony optimization with fireworks algorithm to solve capacitated vehicle routing problem. *Applied Intelligence*. 2023. vol. 53. no. 6. pp. 7326–7342.
9. Gendreau M., Tarantilis C.D. Solving large-scale vehicle routing problems with time windows: The state-of-the-art. Montreal, QC, Canada: Cirreht, 2010.
10. Khan M.M.R., Siddique M.A.B., Arif R.B., Oishe M.R. Adbscan: Adaptive density-based spatial clustering of applications with noise for identifying clusters with varying densities. *4th International Conference on Electrical Engineering and Information Communication Technology (iCEEICT)*. IEEE, 2018. pp. 107–111.
11. Deng D. DBSCAN clustering algorithm based on density. *7th International Forum on Electrical Engineering and Automation (IFEAA)*. IEEE, 2020. pp. 949–953.
12. Kulkarni O., Burhanpurwala A. A survey of advancements in dbscan clustering algorithms for big data. *3rd International conference on Power Electronics and IoT Applications in Renewable Energy and its Control (PARC)*. IEEE, 2024. pp. 106–111.
13. Ho W., Ho G.T., Ji P., Lau H.C. A hybrid genetic algorithm for the multi-depot vehicle routing problem. *Engineering applications of artificial intelligence*. 2008. vol. 21. no. 4. pp. 548–557.
14. Pedram A., Sorooshian S., Mulubrhan F., Abbaspour A. Incorporating vehicle-routing problems into a closed-loop supply chain network using a mixed-integer linear-programming model. *Sustainability*. 2023. vol. 15. no. 4.
15. Ding H., Yi P., Ramamurthy B. Cost-optimized reservation and routing for scheduled traffic in optical networks. *Journal of Optical Communications and Networking*. 2013. vol. 5. no. 11. pp. 1215–1226.
16. Zong Z., Wang H., Wang J., Zheng M., Li Y. Rbg: Hierarchically solving large-scale routing problems in logistic systems via reinforcement learning. *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. 2022. pp. 4648–4658.

17. Dhahri, A., Zidi, K., Ghedira, K. Variable neighborhood search based set covering ilp model for the vehicle routing problem with time windows. *Procedia Computer Science*. 2024. vol. 29. pp. 844–854.
18. Capucho J.H., Resendo L.C. ILP model and effective genetic algorithm for routing and spectrum allocation in elastic optical networks. *SBMO/IEEE MTT-S International Microwave Optoelectronics Conference (IMOC)*. IEEE, 2013. pp. 1–5.
19. Konstantakopoulos G.D., Gayialis S.P., Kechagias E.P. Vehicle routing problem and related algorithms for logistics distribution: A literature review and classification. *Operational research*. 2022. vol. 22. no. 3. pp. 2033–2062.
20. Zinov V., Kartak V., Valiakhetova Y. Solving multi-objective rational placement of load-bearing walls problem via genetic algorithm. *Informatics and Automation*. 2025. vol. 24. no. 2. pp. 464–491.
21. Kim B.S.S. Clustering-based improved ant colony optimization for the multi-trip vehicle routing problem with heterogeneous fleet and time windows: An industrial case study. 2025.
22. Gharbi A., Ayari M., El Touati Y. Intelligent agent-controlled elevator system: Algorithm and efficiency optimization. *Informatics and Automation*. 2025. vol. 24. no. 1. pp. 30–50.
23. Lin Y.-K., Chen C.-F., Chou T.-Y. Applying cluster analysis to the vehicle routing problem. *International Conference on Flexible Automation and Intelligent Manufacturing*. Springer, Cham, 2024. pp. 358–365.
24. Li J. Research of density based spatial clustering of applications with noise on TCM patent law evaluation. *IEEE 3rd Eurasia Conference on IOT, Communication and Engineering (ECICE)*. IEEE, 2021. pp. 463–466.
25. Vidal T., Battarra M., Subramanian A., Erdogan G. Hybrid metaheuristics for the clustered vehicle routing problem. *Computers & Operations Research*. 2015. vol. 58. pp. 87–99.
26. Frias N., Johnson F., Valle C. Hybrid algorithms for energy minimizing vehicle routing problem: Integrating clusterization and ant colony optimization. *Ieee Access*, 2023. vol. 11. pp. 125800–125821.
27. Argiolas L. Cluster-based approach for route planning optimization of electric vehicles. Ph.D. dissertation, Politecnico di Torino. 2023.
28. Keerthika A., Berlin Hency V. Reinforcement-learning based energy efficient optimized routing protocol for WSN. *Peer-to-Peer Networking and Applications*. 2022. vol. 15. no. 3. pp. 1685–1704.
29. Granada-Echeverri M., Toro E.M., Santa J.J. A mixed integer linear programming formulation for the vehicle routing problem with backhauls. *International Journal of Industrial Engineering Computations*. 2019. vol. 10. pp. 295–308.
30. Yu X., Liu K. A spatial decision support system for large scale vehicle routing. *International Conference on Measuring Technology and Mechatronics Automation*. 2009. vol. 3. pp. 444–449. doi: 10.1109/ICMTMA.2009.270.
31. Yin C., Fang Q., Li H., Peng Y., Xu X., Tang D. An optimized resource scheduling algorithm based on ga and aco algorithm in fog computing. *The Journal of Supercomputing*. 2024. vol. 80. no. 3. pp. 4248–4285.
32. Mandziuk J. New shades of the vehicle routing problem: Emerging problem formulations and computational intelligence solution methods. *IEEE Transactions on Emerging Topics in Computational Intelligence*. 2019. vol. 3. no. 3. pp. 230–244.
33. Kumar M., Kumar D. Green logistics optimization model for forward and reverse logistics using genetic algorithm. *IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*. IEEE, 2015. pp. 717–720.

34. Ransikarbum K., Chaiyaphan C., Pataratanased R. Analysis of logistical aspect of food-safety system in the green supply chain using vehicle routing problem model. Research, Invention, and Innovation Congress: Innovation Electricals and Electronics (RI2C). IEEE, 2021. pp. 48–53.
35. Leu J.-D., Krischke A., Lee Y.-P., Lee L.J.-H., Huang Y.-W. A green vehicle routing method for the regional logistics center. IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). IEEE, 2018. pp. 71–75.
36. Garside A.K., Ahmad R., Muhtazaruddin M.N.B. A recent review of solution approaches for green vehicle routing problem and its variants. Operations Research Perspectives. 2024.
37. Ester M., Kriegel H.-P., Sander J., Xu X. et al. A density-based algorithm for discovering clusters in large spatial databases with noise. kdd. 1996. vol. 96. no. 34. pp. 226–231.
38. Pulido-Gaytan L.B., Tchernykh A., Nesmachnow S., Cristobal-Salas A., Avetisyan A., Barrera H.E.C., Hernandez C.J.B. Multiobjective optimization of vehicle routing with environmental penalty. Supercomputing: 10th International Conference on Supercomputing in Mexico (ISUM). Springer, Cham, 2019. vol. 1151. pp. 147–162.
39. Cao N.A., Phan T.H., Chinh N.T., Tran D.Q., Nguyen H.N., Trang N.T.T., Choi G.S. Optimizing delivery routing problem for logistics companies based on integer linear programming method. International Journal of Internet, Broadcasting and Communication. 2022. vol. 14. no. 4. pp. 212–221.
40. Maroof A., Ayvaz B., Naeem K. Logistics optimization using hybrid genetic algorithm (hga): a solution to the vehicle routing problem with time windows (vrptw). IEEE Access, 2024.

Cao Ngoc Anh — Lecturer, Faculty of information technology, University of Economics – Technology for Industries (UNETI); Ph.D. student, Institute of information technology, Vietnam National University. Research interests: optimization algorithms, artificial intelligence, machine learning, metaheuristics, intelligent optimization and applications in combinatorial problems such as Vehicle Routing Problem (VRP). The number of publications — 3. cnanh@uneti.edu.vn; Giao Tien – Giao Thuy, Nam Dinh, Viet Nam; office phone: +84(091)259-9122.

Tran Bich Thao — Lecturer, Faculty of information technology, University of Economics – Technology for Industries (UNETI). Research interests: databases, optimization algorithms, artificial intelligence and applications in complex combinatorial problems. The number of publications — 1. tbthao@uneti.edu.vn; Tien Thang – Ly Nhan – Ha Nam, Viet Nam; office phone: +84(094)3931-081.

Tran Ba Hung — Researcher, Institute of information technology, Vietnam Academy of Science and Technology (VAST). Research interests: multimedia communications, network security, artificial intelligence. The number of publications — 1. tbhung@ioit.ac.vn; Tien Duong – Dong Anh, Ha Noi, Viet Nam; office phone: +84(097)742-2419.

Trinh Thu Huong — Lecturer, International training and cooperation institute, East Asia University of Technology. Research interests: logistics and supply chain management, business administration, economics and management. The number of publications — 1. huongtt2@eaut.edu.vn; Dinh Tien – Yen Dinh, Thanh Hoa, Viet Nam; office phone: +84(090)309-4888.

Nguyen Viet Hung — Lecturer, International training and cooperation institute, East Asia University of Technology. Research interests: multimedia communications, network security, artificial intelligence, traffic engineering in next-generation networks, QoE/QoS guarantee for network services, green networking, applications. The number of publications — 27. Corresponding author: hungnv@eaut.edu.vn; Ky Phu – Ky Anh, Ha Tinh, Viet Nam; office phone: +84(098)911-2079.

К. НГОК АНЬ, Т. БИЧ ТАО, Т. БА ХУНГ, Т. ТУ ХУОНГ, Н.В. ХУНГ
**ОПТИМИЗАЦИЯ ТРАНСПОРТНЫХ РАСХОДОВ: ПОВЫШЕНИЕ
ЭФФЕКТИВНОСТИ ЛОГИСТИКИ И ИСПОЛЬЗОВАНИЯ
РЕСУРСОВ В ДИНАМИЧЕСКОЙ СРЕДЕ**

Нгок Ань К., Бич Тао Т., Ба Хунг Т., Ту Хуонг Т., Хунг Н.В. Оптимизация транспортных расходов: повышение эффективности логистики и использования ресурсов в динамической среде.

Аннотация. Растущий спрос на транспортировку товаров, обусловленный расширением глобальных цепочек поставок и растущими ожиданиями клиентов, подчеркивает острую необходимость оптимизации транспортных расходов для повышения эффективности логистики. В условиях быстро развивающегося и конкурентного рынка предприятия сталкиваются с растущими проблемами в управлении сложными транспортными сетями, минимизации эксплуатационных расходов и удовлетворении разнообразных требований клиентов. Для решения этих проблем в данной статье представлено решение, разработанное для снижения транспортных расходов за счет оптимизации потока товаров и повышения эффективности использования ресурсов. Используя передовые методы оптимизации и стратегии на основе данных, предлагаемое решение позволяет выявить неэффективности, упростить процесс принятия решений и улучшить распределение ресурсов. Первые результаты показывают, что этот подход не только значительно снижает эксплуатационные расходы, но и повышает способность предприятий быстро и эффективно реагировать на меняющиеся требования клиентов, обеспечивая как экономическую эффективность, так и удовлетворенность клиентов. Однако по мере дальнейшего развития логистической отрасли и увеличения объемов транзакций ожидается, что сценарии транспортировки станут более сложными, а требования клиентов – более разнообразными. Эти изменения требуют дальнейшего совершенствования и масштабируемости предложенного решения для работы с расширенными сетями, более сложными логистическими задачами и широким спектром потребительских требований. В будущих исследованиях приоритетное внимание будет уделено разработке крупномасштабных моделей, способных включать больше переменных, повышать вычислительную эффективность и обеспечивать более быстрое и точное принятие решений в условиях растущей сложности логистического сектора. Таким образом, предлагаемое решение представляет собой значительный шаг вперед в оптимизации транспортных расходов и повышении эффективности логистики. Первые результаты показывают, что данное решение позволяет сократить транспортные расходы на 19,02–29,65% и повысить вычислительную эффективность в задачах маршрутизации малого и среднего масштаба (10-20 клиентов). Несмотря на его потенциал, необходимы дополнительные исследования для обоснования масштабируемости для более крупных наборов данных. Таким образом, наш подход обеспечивает прочную основу для оптимизации логистики с четкими перспективами расширения и адаптации в реальных условиях.

Ключевые слова: задача маршрутизации транспортных средств (VRP), линейное программирование (LP), оптимизация методом муравьиных колоний (ACO), целочисленное линейное программирование (ILP), DBSCAN, генетические алгоритмы (GA).

Литература

1. Mageswari M.N. Vehicle routing problem (vrp) using genetic algorithm. *Science*. 2024. vol. 9. no. 3. pp. 1–3.
2. Wang Q., Peng S., Liu S. Optimization of electric vehicle routing problem using tabu search. *Chinese Control and Decision Conference (CCDC)*. IEEE, 2020. pp. 2220–2224.
3. Zhang Q., Wu L., Li J. Application of Improved Scatter Search Algorithm to Reverse Logistics VRP Problem. *IEEE 5th International Conference on Power, Intelligent Computing and Systems (ICPICS)*. IEEE, 2023. pp. 283–288.
4. Alolaiwy M., Hawsawi T., Zohdy M., Kaur A., Louis S. Multiobjective Routing Optimization in Electric and Flying Vehicles: A Genetic Algorithm Perspective. *Applied Sciences*. 2023. vol. 13. no. 18.
5. Ni Q., Tang Y. A Bibliometric Visualized Analysis and Classification of Vehicle Routing Problem Research. *Sustainability*. 2023. vol. 15. no. 9.
6. Kim B.S., Mozhehi A., Wang Y., Sun S., Wang X. Clustering Based Enhanced Ant Colony Optimization for Multi-Trip Vehicle Routing Problem with Heterogeneous Fleet and Time Windows: An Industrial Case Study. *Proceedings of the 17th ACM SIGSPATIAL International Workshop on Computational Transportation Science GenAI and Smart Mobility Session*. 2024. pp. 46–55.
7. Gaon T., Gabay Y., Weiss Cohen M. Optimizing electric vehicle routing efficiency using k-means clustering and genetic algorithms. *Future Internet*. 2025. vol. 17. no. 3.
8. Gao Y., Wu H., Wang W. A hybrid ant colony optimization with fireworks algorithm to solve capacitated vehicle routing problem. *Applied Intelligence*. 2023. vol. 53. no. 6. pp. 7326–7342.
9. Gendreau M., Tarantilis C.D. Solving large-scale vehicle routing problems with time windows: The state-of-the-art. Montreal, QC, Canada: Cirrelt, 2010.
10. Khan M.M.R., Siddique M.A.B., Arif R.B., Oishe M.R. Adbscan: Adaptive density-based spatial clustering of applications with noise for identifying clusters with varying densities. *4th International Conference on Electrical Engineering and Information Communication Technology (iCEEICT)*. IEEE, 2018. pp. 107–111.
11. Deng D. DBSCAN clustering algorithm based on density. *7th International Forum on Electrical Engineering and Automation (IFEEA)*. IEEE, 2020. pp. 949–953.
12. Kulkarni O., Burhanpurwala A. A survey of advancements in dbscan clustering algorithms for big data. *3rd International conference on Power Electronics and IoT Applications in Renewable Energy and its Control (PARC)*. IEEE, 2024. pp. 106–111.
13. Ho W., Ho G.T., Ji P., Lau H.C. A hybrid genetic algorithm for the multi-depot vehicle routing problem. *Engineering applications of artificial intelligence*. 2008. vol. 21. no. 4. pp. 548–557.
14. Pedram A., Sorooshian S., Mulubrhan F., Abbaspour A. Incorporating vehicle-routing problems into a closed-loop supply chain network using a mixed-integer linear-programming model. *Sustainability*. 2023. vol. 15. no. 4.
15. Ding H., Yi P., Ramamurthy B. Cost-optimized reservation and routing for scheduled traffic in optical networks. *Journal of Optical Communications and Networking*. 2013. vol. 5. no. 11. pp. 1215–1226.
16. Zong Z., Wang H., Wang J., Zheng M., Li Y. Rbg: Hierarchically solving large-scale routing problems in logistic systems via reinforcement learning. *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. 2022. pp. 4648–4658.
17. Dhahri, A., Zidi, K., Ghedira, K. Variable neighborhood search based set covering ilp model for the vehicle routing problem with time windows. *Procedia Computer Science*. 2024. vol. 29. pp. 844–854.

18. Capucho J.H., Resendo L.C. ILP model and effective genetic algorithm for routing and spectrum allocation in elastic optical networks. SBMO/IEEE MTT-S International Microwave Optoelectronics Conference (IMOC). IEEE, 2013. pp. 1–5.
19. Konstantakopoulos G.D., Gayialis S.P., Kechagias E.P. Vehicle routing problem and related algorithms for logistics distribution: A literature review and classification. *Operational research*. 2022. vol. 22. no. 3. pp. 2033–2062.
20. Zinov V., Kartak V., Valiakhmetova Y. Solving multi-objective rational placement of load-bearing walls problem via genetic algorithm. *Informatics and Automation*. 2025. vol. 24. no. 2. pp. 464–491.
21. Kim B.S.S. Clustering-based improved ant colony optimization for the multi-trip vehicle routing problem with heterogeneous fleet and time windows: An industrial case study. 2025.
22. Gharbi A., Ayari M., El Touati Y. Intelligent agent-controlled elevator system: Algorithm and efficiency optimization. *Informatics and Automation*. 2025. vol. 24. no. 1. pp. 30–50.
23. Lin Y.-K., Chen C.-F., Chou T.-Y. Applying cluster analysis to the vehicle routing problem. *International Conference on Flexible Automation and Intelligent Manufacturing*. Springer, Cham, 2024. pp. 358–365.
24. Li J. Research of density based spatial clustering of applications with noise on TCM patent law evaluation. *IEEE 3rd Eurasia Conference on IOT, Communication and Engineering (ECICE)*. IEEE, 2021. pp. 463–466.
25. Vidal T., Battarra M., Subramanian A., Erdogan G. Hybrid metaheuristics for the clustered vehicle routing problem. *Computers & Operations Research*. 2015. vol. 58. pp. 87–99.
26. Frias N., Johnson F., Valle C. Hybrid algorithms for energy minimizing vehicle routing problem: Integrating clusterization and ant colony optimization. *Ieee Access*, 2023. vol. 11. pp. 125800–125821.
27. Argiolas L. Cluster-based approach for route planning optimization of electric vehicles. Ph.D. dissertation, Politecnico di Torino. 2023.
28. Keerthika A., Berlin Hency V. Reinforcement-learning based energy efficient optimized routing protocol for WSN. *Peer-to-Peer Networking and Applications*. 2022. vol. 15. no. 3. pp. 1685–1704.
29. Granada-Echeverri M., Toro E.M., Santa J.J. A mixed integer linear programming formulation for the vehicle routing problem with backhauls. *International Journal of Industrial Engineering Computations*. 2019. vol. 10. pp. 295–308.
30. Yu X., Liu K. A spatial decision support system for large scale vehicle routing. *International Conference on Measuring Technology and Mechatronics Automation*. 2009. vol. 3. pp. 444–449. doi: 10.1109/ICMTMA.2009.270.
31. Yin C., Fang Q., Li H., Peng Y., Xu X., Tang D. An optimized resource scheduling algorithm based on ga and aco algorithm in fog computing. *The Journal of Supercomputing*. 2024. vol. 80. no. 3. pp. 4248–4285.
32. Mandziuk J. New shades of the vehicle routing problem: Emerging problem formulations and computational intelligence solution methods. *IEEE Transactions on Emerging Topics in Computational Intelligence*. 2019. vol. 3. no. 3. pp. 230–244.
33. Kumar M., Kumar D. Green logistics optimization model for forward and reverse logistics using genetic algorithm. *IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*. IEEE, 2015. pp. 717–720.
34. Ransikarbum K., Chaiyaphan C., Pataratanased R. Analysis of logistical aspect of food-safety system in the green supply chain using vehicle routing problem model. *Research, Invention, and Innovation Congress: Innovation Electricals and Electronics (RI2C)*. IEEE, 2021. pp. 48–53.

35. Leu J.-D., Krischke A., Lee Y.-P., Lee L.J.-H., Huang Y.-W. A green vehicle routing method for the regional logistics center. IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). IEEE, 2018. pp. 71–75.
36. Garside A.K., Ahmad R., Muhtazaruddin M.N.B. A recent review of solution approaches for green vehicle routing problem and its variants. Operations Research Perspectives. 2024.
37. Ester M., Kriegl H.-P., Sander J., Xu X. et al. A density-based algorithm for discovering clusters in large spatial databases with noise. kdd. 1996. vol. 96. no. 34. pp. 226–231.
38. Pulido-Gaytan L.B., Tchernykh A., Nesmachnow S., Cristobal-Salas A., Avetisyan A., Barrera H.E.C., Hernandez C.J.B. Multiobjective optimization of vehicle routing with environmental penalty. Supercomputing: 10th International Conference on Supercomputing in Mexico (ISUM). Springer, Cham, 2019. vol. 1151. pp. 147–162.
39. Cao N.A., Phan T.H., Chinh N.T., Tran D.Q., Nguyen H.N., Trang N.T.T., Choi G.S. Optimizing delivery routing problem for logistics companies based on integer linear programming method. International Journal of Internet, Broadcasting and Communication. 2022. vol. 14. no. 4. pp. 212-221.
40. Maroof A., Ayvaz B., Naeem K. Logistics optimization using hybrid genetic algorithm (hga): a solution to the vehicle routing problem with time windows (vrptw). IEEE Access, 2024.

Нгок Ань Као — преподаватель, факультет информационных технологий, Университет экономики – Технологии для промышленности; аспирант, институт информационных технологий, Вьетнамский национальный университет. Область научных интересов: алгоритмы оптимизации, искусственный интеллект, машинное обучение, метаэвристика, интеллектуальная оптимизация и приложения в комбинаторных задачах маршрутизации транспортных средств (VRP). Число научных публикаций — 3. cnanh@uneti.edu.vn; Зяо Тьен – Зяо Туй, Намдинь, Вьетнам; р.т.: +84(091)259-9122.

Бич Тао Тран — преподаватель, факультет информационных технологий, Университет экономики – Технологии для промышленности. Область научных интересов: базы данных, алгоритмы оптимизации, искусственный интеллект, приложения в сложных комбинаторных задачах. Число научных публикаций — 1. tbthao@uneti.edu.vn; Тьен Тханг – Ли Нян – Ха Нам, Вьетнам; р.т.: +84(094)3931-081.

Ба Хунг Тран — научный сотрудник, институт информационных технологий, Вьетнамская академия наук и технологий. Область научных интересов: мультимедийные коммуникации, сетевая безопасность, искусственный интеллект. Число научных публикаций — 1. tbhung@ioit.ac.vn; Тьен Дуонг – Донг Ань, Ханой, Вьетнам; р.т.: +84(097)742-2419.

Ту Хуонг Тринь — преподаватель, международный институт подготовки кадров и сотрудничества, Восточноазиатский технологический университет. Область научных интересов: логистика и управление цепями поставок, деловое администрирование, экономика и менеджмент. Число научных публикаций — 1. huongtt2@eaut.edu.vn; Динь Тьен – Йен Динь, Тханьхоа, Вьетнам; р.т.: +84(090)309-4888.

Хунг Нгуен Вьет — преподаватель, международный институт подготовки кадров и сотрудничества, Восточноазиатский технологический университет. Область научных интересов: мультимедийные коммуникации, сетевая безопасность, искусственный интеллект, организация трафика в сетях нового поколения, гарантия качества сетевых услуг, экологичные сети, приложения. Число научных публикаций — 27. hungnv@eaut.edu.vn; Ки Фу – Ки Ань, Хатинь, Вьетнам; р.т.: +84(098)911-2079.

А.Б. МИГРАНОВ
**МОДИФИЦИРОВАННЫЕ ЭВРИСТИЧЕСКИЕ АЛГОРИТМЫ
РАСПРЕДЕЛЕНИЯ ЗАДАНИЙ ДЛЯ ГРУПП МОБИЛЬНЫХ
РОБОТОВ В УСЛОВИЯХ НЕОПРЕДЕЛЕННОСТИ**

Мигранов А.Б. Модифицированные эвристические алгоритмы распределения заданий для групп мобильных роботов в условиях неопределенности.

Аннотация. Рассматривается проблема распределения заданий между группами мобильных роботов в условиях параметрической и стохастической неопределенности, возникающей из-за сенсорных погрешностей, нестационарности среды и ограниченности информации об объектах управления. Основная цель работы – адаптировать разработанные ранее эвристические алгоритмы к реальным условиям, где присутствуют сенсорные ошибки и недостаток информации о состоянии среды. В качестве базовых подходов рассматриваются три алгоритма: муравьиный алгоритм, нейронная сеть Хопфилда и генетический алгоритм. Разработаны специальные модификации для каждого алгоритма, учитывающие неопределенность исходных данных: динамическое обновление феромонных следов, адаптивная коррекция весовых коэффициентов нейронов и интервальная оценка параметров среды. Приведены общая постановка задачи, математические модели и принципы построения предложенных алгоритмов распределения заданий. Было проведено численное моделирование для сравнения модифицированных версий алгоритмов с их базовыми аналогами в условиях различных уровней неопределенности функционирования системы. Установлено, что предложенные адаптивные механизмы улучшают эффективность распределения заданий до 20 % по сравнению с базовыми методами. На основании полученных результатов сформулированы рекомендации по выбору оптимального алгоритма в зависимости от конкретных условий функционирования системы и задач управления. Сделан вывод о целесообразности использования разработанных подходов при проектировании интеллектуальных адаптивных систем группового управления мобильными роботами. Предложенные решения могут применяться и для более широкого круга задач, включая динамическое переназначение ресурсов и организацию кооперативного поведения технических агентов.

Ключевые слова: распределение заданий, эвристические алгоритмы, группы мобильных роботов, муравьиный алгоритм, нейронная сеть Хопфилда, генетический алгоритм.

1. Введение. Группы мобильных роботов применяются в промышленности, логистике, сельском хозяйстве и при ликвидации последствий ЧС, поскольку они необходимы для выполнения работ в опасных или труднодоступных для человека условиях [1 – 4]. Одной из важных задач в подобных системах является эффективное распределение заданий между роботами, которое минимизирует затраты ресурсов и время выполнения миссии [5 – 8]. В этих условиях особенно важно создавать алгоритмы, способные адаптироваться к динамике среды и неопределенности исходных данных [9 – 13].

Задача распределения заданий между мобильными роботами является NP-сложной, поэтому методы полного перебора не применимы даже при сравнительно небольшом количестве агентов и задач. В связи с этим в литературе предложен ряд эвристических методов распределения заданий, позволяющих получать приемлемые решения за разумное время. К числу таких методов относятся муравьиные алгоритмы [14, 15], нейронные сети, в частности сеть Хопфилда [16], и генетические алгоритмы [17]. Их применение позволяет эффективно решать задачи распределения, маршрутизации и планирования [18 – 23].

1.1. Современное состояние исследований в области эвристических методов распределения заданий

1.1.1. Тенденции 2019-2025 гг. В последние пять лет внимание исследователей направлено на гибридные алгоритмы, объединяющие классические методы и машинное обучение. В [1] представлен метод двойной адаптации феромона, ускоряющий сходимость. В настоящей работе, в отличие от [1], где оптимизировались только длина маршрута и время, основным критерием является интегральный энергетический показатель J , включающий индивидуальные удельные энергозатраты роботов. Схема также учитывает динамическое появление новых заданий и блокировку узлов, что также не рассматривалось в [1].

В [2] модель «rendezvous consensus (консенсус сбора)» дополнена вероятностными весовыми коэффициентами для повышения устойчивости к пропаданию связи между агентами. Параллельно развивается оптимизация с суррогатными моделями: в [24] объединили генетический алгоритм с евклидовой геометрией и гибридным оператором кроссовера, что позволило значительно сократить время оценки фитнес-функции при неизменном качестве решения; в [25] применили метамоделли на базе случайного леса для предварительного ранжирования хромосом, тем самым уменьшая число ресурсоемких прямых вычислений. Сетевые методы также совершенствуются: в обзоре [26] показано, что сочетание рекуррентных нейронных сетей и роевых методов повышает предсказуемость сходимости в задачах VRP с динамическими ограничениями.

К основным тенденциям современных исследований относятся:

- адаптивность параметров (адаптивная настройка параметров α , β , ρ и др. в процессе работы);
- устойчивость к сенсорным шумам и отказам агентов;
- масштабируемость на группы > 50 роботов за счет параллельных вычислений и распределенных архитектур;

– интеграция обучаемых компонент (выбор операторов, предсказание границ поиска).

1.1.2. Выбор эвристических алгоритмов. Классические задачи VRP/TSP решаются множеством эвристических подходов и в литературе описаны десятки модификаций муравьиных алгоритмов (МА), нейронных сетей Хопфилда (НС), генетических алгоритмов, а также PSO, Bee Colony, Tabu Search, Simulated Annealing [27 – 29] и др. Однако в условиях неоднородной энергетики роботов, динамического поступления новых заданий и возможной блокировки узлов многие из указанных методов требуют адаптации к условиям задачи, включая учет неоднородности и динамики. Систематический анализ публикаций [1, 14 – 20, 24 – 26] показывает, что МА, НС и ГА наиболее широко применяются по соотношению «качество–время» для малых и средних групп роботов ($n \leq 50$, $m \leq 100$):

– МА применяются в задачах маршрутизации при статических условиях благодаря возможности параллельной реализации и относительной простоте алгоритмической структуры [14].

– НС обладает прозрачной энергетической функцией и очень быстрое вычисление при $n \leq 10$ [16].

– ГА отличается гибкостью благодаря широкому набору операторов и хорошо переносится на стохастические постановки [17].

Следует также отметить коммерческие VRP-решатели (ArcGIS VRP, Routific, OR-Tools VRP), которые используют детерминированные модели с однородным парком транспортных средств, не учитывая энергопотребление каждого агента и неполные данные датчиков. API этих систем рассчитан на разовую загрузку задачи, тогда как в данной постановке допускается потоковое поступление новых заданий, роботов и блокировку узлов.

Выбор указанных алгоритмов и их адаптация соответствуют современному уровню исследований и восполняет отсутствие комплексного сравнения различных версий МА, НС и ГА в одной и той же постановке. Кроме того, практика создания групповых робототехнических систем в ИМех УФИЦ РАН [18 – 20] опирается на эти разновидности алгоритмов, что показывает практическую применимость выбранных методов в прикладных проектах.

1.2. Цели и задачи работы. Данная работа посвящена разработке и сравнительному анализу модифицированных эвристических алгоритмов распределения заданий между мобильными роботами в условиях параметрической и стохастической неопределенности. В настоящей работе основное внимание уделяется

учету сенсорных погрешностей, возможным сбоям агентов, изменению числа задач в процессе выполнения и неполной информированности агентов о глобальном состоянии системы. Объектом анализа являются модифицированные версии муравьиного алгоритма, сети Хопфилда и генетического алгоритма, реализованные с учетом указанных факторов. Представлены математические модели задачи, принципы построения соответствующих алгоритмов и результаты численных экспериментов. На основе анализа делаются выводы о целесообразности применения каждого из подходов в зависимости от условий функционирования системы.

Настоящее исследование направлено на развитие моделей, описанных в работе [30], с учетом влияния неопределенностей, характерных для реальных условий эксплуатации мобильных роботов. В отличие от предыдущей работы [30], где алгоритмы распределения задач рассматривались в номинальных условиях, в данной статье предлагаются их модифицированные версии, ориентированные на обработку данных с погрешностями и изменяющимися параметрами. Кроме того, проведен количественный анализ устойчивости получаемых решений.

Основная цель работы – повысить устойчивость и воспроизводимость распределения заданий в группах мобильных роботов в условиях параметрической и стохастической неопределенности. Для достижения этой цели были поставлены и решены четыре взаимосвязанные задачи:

1. Формализовать задачу распределения заданий с учетом энергозатрат и динамики количества роботов и задач.
2. Разработать модифицированные версии муравьиного алгоритма, нейросети Хопфилда и генетического алгоритма с механизмами адаптации к шумам и отказам.
3. Провести численное моделирование, сравнить предложенные алгоритмы с классическими по показателям устойчивости и вычислительной сложности.
4. Сформулировать практические рекомендации по выбору алгоритма в зависимости от ограничений по энергоресурсам, времени и качеству связи.

Научная новизна работы заключается в разработке модифицированных версий следующих эвристических алгоритмов: муравьиного алгоритма с динамическим обновлением феромонов, нейросети Хопфилда с адаптивной корректировкой порогов активации нейронов и генетического алгоритма с интервальными оценками параметров. Это позволяет повысить устойчивость маршрутов на 15–

20 % и снизить разброс результатов не менее чем на 22 % по сравнению с базовыми версиями алгоритмов. Разработанные алгоритмы обеспечивают устойчивость получаемых решений в условиях параметрической и стохастической неопределенности. В рамках единой постановки задачи реализованы механизмы, обеспечивающие устойчивость к изменениям исходных данных. Численное моделирование и сравнительный анализ эффективности каждого метода подтвердили обоснованность предложенных подходов.

2. Математическая формализация задачи распределения

2.1. Исходные обозначения. Рабочее пространство группы мобильных роботов представляет собой прямоугольную область

$$\Omega = [0, L_x] \times [0, L_y] \subset \mathbb{R}^2,$$

где $L_x, L_y > 0$ – размеры области в условных единицах длины (у.е.д.).

В начальный момент времени $t = 0$ на поле находятся множество роботов $R(0) = \{r_i\}_{i=1}^n$, $r_i = (x_i, y_i)$ и множество заданий

$T(0) = \{t_j\}_{j=1}^m$, $t_j = (\xi_j, \eta_j)$. Параметры i -го робота выражены в условных единицах энергии (у.е.э.) и включают:

E_i^{start} – начальный запас энергии;

c_i^{move} – удельные энергозатраты на перемещение;

c_i^{task} – удельные энергозатраты на выполнение задания;

v_i – скорость перемещения (у.е.д./с).

2.2. Маршрут и его длина. Маршрут робота r_i задается упорядоченным списком вершин

$$P_i = \{p_{i,0}, p_{i,1}, \dots, p_{i,K_i}\}, \quad p_{i,0} = r_i, \quad p_{i,K_i} \in T.$$

Длина маршрута определяется как

$$L_i = \sum_{k=0}^{K_i-1} \|p_{i,k+1} - p_{i,k}\|_2, \quad (1)$$

а время движения $T_i^{\text{move}} = L_i / v_i$.

2.3. Критерий оптимизации. Полные энергозатраты группы:

$$J = \sum_{i=1}^n \left(E_i^{\text{start}} + c_i^{\text{move}} L_i + c_i^{\text{task}} T_i^{\text{task}} \right). \quad (2)$$

Для оптимизации целевой функции требуется $\min_{P_1, \dots, P_n} J$.

2.4. Переменные назначения и ограничения. Вводится бинарная матрица $x_{ij} \in \{0, 1\}$: задача t_j назначена роботу r_i .

$$\begin{aligned} \sum_{i=1}^n x_{ij} &= 1, j = 1, \dots, m \\ \sum_{j=1}^m x_{ij} &\leq Q_i, i = 1, \dots, n, \end{aligned} \quad (3)$$

где Q_i ограничивает максимальное число задач робота r_i (при необходимости). Маршрут P_i строится на подмножестве $T_i = \{t_j \mid x_{ij} = 1\}$.

2.5. Динамическая постановка. На каждом дискретном шаге $t = 0, 1, \dots$:

$$\begin{aligned} R(t+1) &= R(t) \cup R_{\text{new}}(t) \setminus R_{\text{lost}}(t), \\ T(t+1) &= T(t) \cup T_{\text{new}}(t) \setminus T_{\text{done}}(t), \end{aligned}$$

где R_{new} – новые роботы, появившиеся в системе после старта (например, подключились к группе позже, заменили вышедших из строя и т.п.); R_{lost} – вышедшие из строя роботы, которые больше не участвуют в выполнении заданий (из-за поломки, потери связи и т.п.); T_{new} – новые задания, поступившие в систему в процессе работы (например, срочные задачи, пришедшие в реальном времени); T_{done} – выполненные задания, т.е. те, которые уже были завершены (и могут быть исключены из активной постановки).

Координаты и энергетические параметры подвергаются стохастическим возмущениям $(\delta_x, \delta_y) \sim \mathcal{N}(0, \sigma^2)$, $\delta_c \sim \mathcal{N}(0, \sigma_c^2)$. Алгоритм распределения вычисляет $x_{ij}(t)$ и $P_i(t)$ в масштабе реального времени.

2.6. Связь с NP-трудными задачами. Статическая версия (фиксированные R, T) эквивалентна задаче маршрутизации с несколькими депо и разнородным парком (MDVRP/HVRP). Введением фиктивных вершин-депо и дуг нулевого веса задача сводится к TSP [31], что обосновывает применение эвристических и метаэвристических методов, рассмотренных в следующем разделе.

3. Эвристические подходы к распределению заданий. В постановке задачи (1)–(3) ее прямое решение требует перебора $O((m+n)!)^1$ маршрутов, что неприемлемо уже при $m > 10$. Как один из методов решения, используются метаэвристические методы – приближенные алгоритмы, имитирующие природные или эволюционные процессы и обеспечивающие квазиоптимальные решения за полиномиальное время. К ним относятся муравьиные алгоритмы, рекуррентные нейронные сети (модель Хопфилда) и генетические алгоритмы. Каждый метод по-разному распределяет качество решения и вычислительную сложность [24] (таблица 1).

Таблица 1. Сравнительные характеристики метаэвристических методов

Критерий	Муравьиные алгоритмы	Сеть Хопфилда	Генетический алгоритм
Сходимость ($n \leq 20, m \leq 40$)	Быстрая	Быстрая	Умеренная
Настраиваемость	Высокая	Ограниченная	Высокая
Интерпретируемость	Средняя	Высокая	Средняя

Пояснения к таблице 1:

1. Сходимость – среднее время достижения устойчивого значения целевой функции J . «Быстрая» – не более 0.3 с; «умеренная» – до 1.0 с; «медленная» – свыше 1.0 с.

2. Настраиваемость – способность алгоритма сохранять качество решения при изменении внутренних параметров (в пределах 20%). «Высокая» – $\Delta J \leq 5\%$; «ограниченная» – $5\% < \Delta J \leq 15\%$; «низкая» – $\Delta J > 15\%$.

3. Интерпретируемость – возможность аналитически объяснить полученное решение. «Высокая» – энергетическая функция явно задана; «Средняя» – эвристика прослеживается; «Низкая» – решение формируется «черным ящиком».

Следующие разделы 3.1–3.3 описывают модифицированные версии указанных методов в соответствии с математической постановкой задачи (раздел 2).

3.1. Муравьиный алгоритм распределения заданий с учетом неопределенностей. Муравьиные алгоритмы моделируют косвенное взаимодействие агентов через феромонные следы. В адаптированной версии каждая «муравьиная» особь строит допустимый маршрут по множеству заданий T , минимизируя критерий (2).

Пусть к моменту t муравей k из колонии x находится в вершине i ; множество еще не посещенных вершин обозначено J_k . Вероятность перехода в вершину $j \in J_k$ определяется

$$P_{ij}^{k,x}(t) = \frac{[\tau_{ij}^x(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{s \in J_k} [\tau_{is}^x(t)]^\alpha [\eta_{is}]^\beta}, \quad (4)$$

где $\tau_{ij}^x(t)$ – плотность феромона колонии x на ребре (i, j) ; $\eta_{ij} = 1 / \|i - j\|_2$ – эвристическая привлекательность; $\alpha, \beta > 0$ – веса «опыта» и «зрения» соответственно.

После завершения всех маршрутов поколения t концентрация феромона обновляется

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \sum_{k=1}^A \frac{Q}{L_k} \delta_{ij}^{(k)}, \quad 0 < \rho < 1, \quad (5)$$

где A – число муравьев, L_k – длина маршрута k (1), $\delta_{ij}^{(k)} = 1$ если ребро (i, j) вошло в маршрут k , иначе 0; $Q > 0$ – безразмерный коэффициент.

При появлении препятствия или изменении параметров задания значение феромона на затронутых ребрах корректируется:

$$\tau_{ij} = \begin{cases} \tau_{ij} \times (1 - \gamma), & \text{если появилось препятствие,} \\ \tau_{ij}, & \text{иначе,} \end{cases} \quad (6)$$

а множество допустимых вершин J_k пересчитывается в реальном времени. Дополнительно вводится коэффициент стабильности s_{ij} – доля итераций, в которых ребро оказалось в лучшем маршруте; при вычислении вероятности (4) термин η_{ij} заменяется на $\eta_{ij} s_{ij}$.

В условиях неопределенности (например, возможных отказов, появления новых задач или изменения доступности маршрутов) формула (6) используется для адаптации алгоритма и включает:

- динамическую коррекцию феромонных следов;
- локальное перестроение маршрутов при появлении новых задач;
- приоритетные веса для устойчивых решений (например, включение показателя стабильности в целевую функцию).

По завершении итерации для каждого лучшего маршрута P_i фиксируются бинарные переменные x_{ij} (3), таким образом алгоритм генерирует допустимое решение задачи (1)–(2).

3.2. Численные эксперименты и сравнительный анализ эффективности муравьиного алгоритма. Эксперименты проводились с целью количественной оценки эффективности модифицированного муравьиного алгоритма по критерию суммарной энергии J (2) и времени вычислений. Рассмотрены два сценария:

- сценарий S1 (номинальный): фиксированный набор роботов и задач, без внешних возмущений;
- сценарий S2 (динамический): на 50-й итерации блокируется случайный узел, что требует адаптивной перестройки маршрутов.

3.2.1. Входные данные. Координаты роботов и задач генерируются случайно из равномерного распределения $U(0, L_x) \times U(0, L_y)$, где $L_x = L_y = 100$ у.е.д. Рассмотрены следующие размеры задач:

- набор N_1 : 10 заданий и 5, 10 или 15 роботов;
- набор N_2 : 20 заданий и 5, 10 или 15 роботов;
- набор N_3 : 30 заданий и 5, 10 или 15 роботов.

Для каждого сочетания параметров выполнялось 20 независимых запусков.

3.2.2. Настройки алгоритма. Параметры алгоритма выбраны следующим образом:

$$\alpha = 1, \beta = 3, \rho = 0.30, Q = 100, A = R,$$

где A – количество агентов (равное количеству роботов R).

Выбор $\alpha = 1$ и $\beta = 3$ основан на рекомендуемом интервале значений $\alpha \in [1; 2]$, $\beta \in [2; 5]$, традиционно применяемый в МА для задач маршрутизации [32]. Значение $\rho = 0.30$ определено по

результатам однофакторного численного эксперимента, в котором параметр ρ варьировался на четырех уровнях: 0.15, 0.20, 0.30 и 0.40. При $\alpha = 1$ и $\beta = 3$, значение $\rho = 0.30$ обеспечило наименьшее значение энергетического критерия J и стабильность получаемых результатов: отклонение J по 20 сериям запусков не превышало 0.8 % от среднего значения (при $n = 10$, $m = 20$). Для Q принято стандартное значение, широко используемое в классических реализациях МА [32].

Максимальное количество итераций – $N_{\text{iter}} = 100$.


Вычисления выполнялись в среде Matlab 2020a на процессоре Intel i7-11700 (1 поток).

3.2.3. Результаты сценария S_1 . Результаты усреднены по 20 запускам. В таблице 2 приведены средние значения и стандартные отклонения. Рисунок 1 иллюстрирует динамику феромонного поля на примере $N_1/10$ роботов.

Таблица 2. Средние длины маршрутов и время вычислений в сценарии S_1

Набор	Число роботов	Средняя длина маршрута (у.е.д.)	Время вычислений (с)
N_1	5	13.02 ± 0.11	0.081 ± 0.006
N_1	10	10.04 ± 0.09	0.085 ± 0.005
N_1	15	3.02 ± 0.03	0.112 ± 0.007
N_2	5	19.98 ± 0.14	0.072 ± 0.005
N_2	10	7.06 ± 0.08	0.145 ± 0.010
N_2	15	9.11 ± 0.10	0.243 ± 0.015
N_3	5	9.12 ± 0.12	0.119 ± 0.007
N_3	10	2.04 ± 0.02	0.208 ± 0.012
N_3	15	2.05 ± 0.02	0.338 ± 0.018

Из таблицы 2 следует, что увеличение числа роботов приводит к снижению средней длины маршрута, особенно заметному при малом количестве задач благодаря улучшенному покрытию рабочего поля роботами. Рост числа заданий увеличивает вычислительное время, что объясняется возрастанием вычислительной сложности при увеличении размерности задачи. При $R \geq 0.5T$ прирост эффективности по длине маршрута замедляется.


Рис. 1. Граф рабочего поля на примере $N_1/10$ роботов

3.2.4. Результаты сценария S_2 . В динамическом сценарии S_2 в момент 50-й итерации случайный узел помечается как недоступный. Модифицированный алгоритм с адаптацией феромонов (6) смог удерживать допустимые маршруты во всех 60 тестах, в то время как базовый алгоритм без адаптации при появлении препятствия не учитывал изменения доступности узлов, что формировало недопустимый маршрут.

Среднее увеличение целевого функционала J в сравнении с номинальным сценарием составило 6.4 %. Рисунок 2 показывает пример динамической перестройки маршрутов после блокировки узла.

3.2.5. Выводы. Модифицированный муравьиный алгоритм выполняет задачу при $m \leq 30$ за время < 0.35 с. При большем количестве заданий и роботов может наблюдаться снижение скорости сходимости.

Адаптивный механизм корректировки феромонов улучшает устойчивость к динамическим изменениям среды, повышая вероятность выполнения задачи примерно на 30 %.

Рис. 2. Визуализация сценария S_2

3.3. Модифицированная нейросеть Хопфилда для распределения заданий с учетом неопределенностей. Для каждой потенциальной пары «робот i – задание j » вводится бинарный переменный элемент сети $x_{ij} \in \{0,1\}$: значение 1 указывает, что задание j закреплено за роботом i . Всего сеть содержит $N = n \times m$ элементов.

Оптимальное распределение достигается посредством минимизации энергии

$$E = A \sum_i \left(\sum_j x_{ij} - 1 \right)^2 + B \sum_j \left(\sum_i x_{ij} - 1 \right)^2 + C \sum_{i,j} x_{ij} d_{ij}, \quad (7)$$

где первые два квадратичных слагаемых штрафуют нарушения ограничений «каждое задание – ровно одному роботу и наоборот»; третье слагаемое учитывает стоимость маршрута, d_{ij} – расстояние от робота i до задания j (в условных единицах длины).

Минимизируя E , сеть автоматически формирует допустимое и «дешевое» распределение. Коэффициенты выбираются так, чтобы $A, B \gg C > 0$; в практических тестах использовались $A = B = 5 \cdot 10^2$, $C = 1$. Пояснения к выбранным коэффициентам показаны в таблице 3. Значения подбирались экспериментально для групп до 5 роботов и 10 заданий.

Таблица 3. Рекомендуемые значения A, B, C

Коэффициент	Назначение	Типичное значение
A	запрет «два робота на одно задание»	500
B	запрет «задание не обслужено»	500
C	вес фактической длины маршрута	1

Значения коэффициентов A и B устанавливались по эмпирическому правилу:

$$A = B = 50 \cdot \max(n, m).$$

При типовых конфигурациях ($n \leq 5$, $m \leq 10$) это дает $A = B = 500$. Такое масштабирование обеспечивает штрафной вклад в энергетическую функцию, как минимум в пять раз превышающий максимальную стоимость допустимого назначения:

$$A \geq 5 \cdot C \cdot \max(d_{ij}),$$

что исключает более 99 % нежелательных конфигураций. Принятые значения находятся в том же порядке величин, что и коэффициенты, использованные в оригинальной модели Хопфилда [16].

Элементы сети обновляются асинхронно, что уменьшает вероятность заклинивания алгоритма, но может приводить к неравномерности распределения задач при высоком шуме. Каждый x_{ij} проверяется, и если его переключение $0 \leftrightarrow 1$ уменьшает энергию E , новое состояние фиксируется. Процесс завершается, когда ни одна одиночная перестановка не уменьшает E или по достижении 100 итераций. Такой порог обоснован эмпирически на основе анализа поведения энергетической функции $E(k)$, где k – номер итерации. В ходе 30 серий запусков на задачах с $n \leq 5$, $m \leq 10$ было установлено, что изменение энергии

$$\Delta E(k) = |E(k) - E(k-1)|$$

в среднем становится близким к нулю после ≈ 72 итераций. После этого $E(k)$ стабилизируются, а дальнейшее увеличение числа шагов

приводит лишь к росту времени вычислений, без значимого улучшения целевой функции J .

Отметим, что в некоторых экспериментах были случаи преждевременной остановки из-за локальных минимумов.

Координаты роботов и заданий искажаются аддитивным шумом $\delta r_i, \delta t_j \sim \mathcal{N}(0, \sigma^2)$, что влияет лишь на расстояния d_{ij} . Повышение дисперсии шумов компенсируется пропорциональным увеличением коэффициентов штрафа A, B , что предотвращает появление недопустимых назначений при сильном шуме.

Полученная матрица назначений $\{x_{ij}\}$ подставляется в формулы (1)–(3); тем самым определяется значение глобального критерия J и обеспечивается сопоставимость с другими методами.

3.4. Численные эксперименты и сравнительный анализ эффективности нейронной сети. Целью экспериментов является количественная оценка того, как модифицированная сеть Хопфилда сохраняет качество решений при росте сенсорного шума по сравнению с классической (немодифицированной) моделью. В качестве модели неопределенности вводится гауссов шум уровня $\sigma \in \{0.1, 0.2, 0.3\}$ ед. Для каждой комбинации (n, m, σ) выполняется $N = 5$ независимых запусков. Критерием остановки служит либо достижение 100 итераций, либо сходимость изменения энергии $|\Delta E| < 10^{-4}$.

Для объективного сравнения эффективности модифицированной сети с работой базовой модели были искусственно добавлены:

- случайные возмущения в координаты роботов и заданий (для имитации сенсорных ошибок – камеры, лидары, GPS);
- дополнительный шум в процессе обновления потенциалов нейронов (для моделирования реального шума при обработке и передаче информации).

Дополнительный шум отражает типовые источники ошибок в реальных робототехнических системах:

- коммуникационные шумы (задержки, потери пакетов);
- аппаратные ограничения (численные и электронные погрешности);
- модельные упрощения;
- динамические изменения среды (движущиеся препятствия и др.).

3.4.1. Входные данные. Параметры инициализации и работы алгоритмов представлены в таблице 4.

Таблица 4. Настройки эксперимента

Параметр	Значение
Число роботов n	2 и 3
Число заданий m	5 – 8
Уровни шума σ (норм. распр.)	0.1, 0.2, 0.3 (соответствует $\pm 10 \% \dots \pm 30 \%$ типовой ошибки GPS/лидара)
Запусков на комбинацию N_{run}	20
Коэф-ты энергии (7)	$A = B = 5 \cdot 10^2$, $C = 1$
Обновление	Случайный выбор нейрона
Платформа	Matlab 2020a, Intel i7-11700 (1 поток)

3.4.2. Собираемые метрики. В ходе экспериментов сохранялись следующие параметры:

L – суммарная длина маршрутов (1);

J – полный энергетический критерий (2);

σ_L, σ_J – стандартные отклонения по 20 запускам;

T_{conv} – среднее число итераций до сходимости.

Все расстояния и энергии выражены в условных единицах.

3.4.3. Результаты. Для каждой конфигурации (n, m) вычислялись L и J для классической (class) и модифицированной (mod) моделей. Результаты сравнения показаны в таблице 5.

Таблица 5. Сравнение классической и модифицированной сетей (среднее $\pm \sigma$, 20 запусков)

$n / m / \sigma$	L_{class}	L_{mod}	J_{class}	J_{mod}	T_{conv} (ит.)
2 / 5 / 0.1	3.51 ± 0.09	2.96 ± 0.05	26.2 ± 0.8	21.9 ± 0.6	34
2 / 5 / 0.2	3.51 ± 0.12	2.94 ± 0.07	27.8 ± 1.1	23.5 ± 0.7	38
2 / 5 / 0.3	3.60 ± 0.16	3.05 ± 0.10	30.4 ± 1.3	24.9 ± 1.0	42
3 / 8 / 0.1	5.44 ± 0.14	4.69 ± 0.09	48.1 ± 1.2	40.2 ± 1.0	47
3 / 8 / 0.2	5.53 ± 0.18	4.68 ± 0.11	51.7 ± 1.6	42.3 ± 1.1	52
3 / 8 / 0.3	5.72 ± 0.22	4.86 ± 0.14	57.2 ± 2.0	45.1 ± 1.4	57

Рисунок 3 демонстрирует характерные распределения, найденные модифицированной сетью, после 100 итераций при $\sigma = 0.2$.




Рис. 3. Результаты графической визуализации

3.4.4. Анализ результатов. Разница $\Delta L = (L_{\text{class}} - L_{\text{mod}}) / L_{\text{mod}}$ колеблется от 15 % до 20 %. По критерию энергии J преимущество достигает ≈ 22 %.

Стандартное отклонение результатов у модифицированной сети примерно на четверть ниже, чем у классической, что указывает на лучшую воспроизводимость.

Временная сложность: при $n \leq 3, m \leq 8$ сеть сходится в среднем за 40–60 итераций, что эквивалентно < 0.02 с CPU-времени на указанной платформе.

3.4.5. Выводы. Модифицированная нейросеть Хопфилда обеспечивает:

- снижение суммарной длины маршрутов на 15–20 % и полного критерия J на ≈ 22 % при уровнях шума до $\sigma = 0.3$. Однако требуется внимательный подбор коэффициентов штрафов, что является неочевидной задачей;
- более стабильные результаты (меньшие σ) без увеличения числа итераций;
- время вычислений, приемлемое для планирования в реальном времени для малых и средних групп роботов.

3.5. Генетический алгоритм для распределения заданий с учетом неопределенностей. Рассмотрим группу из n роботов и m заданий. Каждая потенциальная стратегия распределения кодируется хромосомой

$$\mathbf{z} = (\mathbf{z}_1, \dots, \mathbf{z}_n), \mathbf{z}_i = (j_1, j_2, \dots) \subset T,$$

где $\mathbf{z}_i$ – упорядоченный список индексов задач, назначенных роботу i .

Используются следующие параметры алгоритма:

P – размер популяции (число хромосом),

$p_c \in [0, 1]$ – вероятность выполнения кроссовера,

$p_m^0 \in [0, 1]$ – базовая вероятность мутации,

$\gamma > 0$ – коэффициент адаптации,

G – число поколений без улучшения,

$G_{\max}$ – максимальное число поколений,

E – число элитных особей, сохраняемых при отборе.

Для особи $\mathbf{z}$ рассчитывается вектор

$$F(\mathbf{z}) = (W_{\Sigma}, T_{\max}, N_{\text{out}}),$$

где $W_{\Sigma} = \sum_{i=1}^n (c_i^{\text{move}} L_i + c_i^{\text{task}} T_i^{\text{task}})$ – показатель затрат энергии на

перемещение и выполнение заданий всеми роботами;

$T_{\max} = \max_{1 \leq i \leq n} T_i^{\text{full}}$; $T_i^{\text{full}} = T_i^{\text{move}} + T_i^{\text{task}}$ – время от старта до завершения последней задачи;

$N_{\text{out}} = m - \sum_i |\mathbf{z}_i|$ – сколько задач осталось без исполнителя.

Величины L_i и T_i^{task} вычисляются по формулам (1)–(3) раздела 2.

Для получения скалярного показателя вводится весовая свертка

$$J(\mathbf{z}) = \lambda_1 W_{\Sigma} + \lambda_2 T_{\max} + \lambda_3 N_{\text{out}}, \quad (8)$$

с коэффициентами

$$\lambda_1 = 1, \lambda_2 = 0.1, \lambda_3 = 100,$$

что делает приоритетом выполнение всех заданий, затем энергетическую экономичность и время.

Модель неопределенности задается с помощью следующих выражений:

1. Координаты объектов (x_j^*, y_j^*) искажены аддитивным шумом $x_j \sim U[x_j^* - \delta_x, x_j^* + \delta_x]$ и аналогично для y_j ;
2. Энергозатраты могут задаваться как нормальные случайные величины

$$c_i^{\text{move}} \sim \mathcal{N}(c_i^0, \sigma_E^2).$$

Приведем основные этапы работы модифицированного ГА:

1. Инициализация.
 - Сгенерировать координаты роботов и заданий с учетом шума δ_x .
 - Задать энергетические параметры $c_i^{\text{move}}, c_i^{\text{task}}$ как интервалы или распределения.
 - Построить начальную популяцию из P допустимых хромосом.
2. Оценка приспособленности.
 - Для каждой хромосомы вычислить L_i и T_i^{full} .
 - Рассчитать $W_\Sigma, T_{\max}, N_{\text{out}}$ и многокритериальный вектор F .
3. Эволюционные операторы.
 - Селекция: отбор родителей турнирным методом по доминированию в пространстве F .
 - Кроссовер: однородный обмен генами с вероятностью p_c .
 - Мутация: случайная перестановка двух задач в хромосоме с вероятностью

$$p_m = p_m^0 + \gamma \sigma_E,$$

где σ_E – текущее стандартное отклонение энергопараметров.

4. Учет неопределенности.
 - Перед каждой оценкой вновь генерировать шум δ_x и шум в c_i^{move} .

– При отборе отдавать предпочтение особям с низкой дисперсией W_{Σ} по нескольким прогонам.

5. Условия остановки.

– Если за G поколений не произошло улучшения J .

– Или достигнуто $G_{\max}$ поколений.

– При этом в каждое новое поколение сохраняются E лучших (элитных) особей.

3.6. Оценка устойчивости и эффективности генетического алгоритма в условиях неопределенности. Для проверки работоспособности и оценки эффективности предложенного ГА были проведены два эксперимента (Matlab 2020a, Intel i7-11700, 1 поток):

Эксперимент E_1 : Проверка устойчивости модифицированного ГА в условиях параметрической неопределенности;

Эксперимент E_2 : Сравнительный анализ модифицированного и классического ГА.

3.6.1. Описание и результаты эксперимента E_1 . В качестве демонстрационного примера рассматривается рабочее поле с 8 роботами и 4 заданиями. Исходные данные приведены в таблице 6.

Таблица 6. Параметры роботов и заданий

Робот	X	Y	Энерго- потребление	Задача	X	Y	Энерго- затраты
R1	6.33	7.62	2.93	T1	4.90	7.78	1.71
R2	9.84	4.88	1.12	T2	5.15	1.76	1.85
R3	1.98	2.28	1.39	T3	8.44	6.07	1.93
R4	2.29	3.62	2.22	T4	5.78	1.02	1.60
R5	6.33	5.13	1.43				
R6	6.53	5.46	1.88				
R7	8.42	4.83	2.06				
R8	1.40	4.45	2.35				

Координаты выражены в условных единицах длины (у.е.д.), энергопотребление и энергозатраты – в условных единицах энергии (у.е.э). В каждом запуске один и тот же номинальный набор исходных данных подвергался следующим параметрическим возмущениям (равномерное распределение):

– координаты (x_j^*, y_j^*) роботов и заданий изменялись на $\pm 0,5$ у.е.д.;

– удельные энергозатраты на перемещение c_i^{move} изменялись на $\pm 0,3$ у.е.э.

Это позволяет оценить устойчивость получаемых решений при неопределенности информации о среде.

В результате работы алгоритма было найдено оптимальное распределение: $T1 \rightarrow R1$, $T2 \rightarrow R5$, $T3 \rightarrow R2$, $T4 \rightarrow R3$. Как показано на рисунке 4, разработанный алгоритм распределения корректно минимизирует суммарные энергетические затраты. Каждая задача назначается одному исполнителю на основе комбинированной оценки расстояния до задачи и индивидуальных энергозатрат робота. Алгоритм стабилизировался к 10-му поколению, достигнув минимального значения функции приспособленности порядка 25.75 условных единиц. Задание T3 назначено роботу R2, а не R7, несмотря на близость R7 к T3, потому что у R2 коэффициент расхода энергии на единицу расстояния ниже. И аналогично задание T2 выполняет робот R5, а не R4, поскольку энергетические характеристики R5 при текущем расположении приводят к меньшей суммарной стоимости, несмотря на большую длину маршрута.




Рис. 4. Визуализация результатов

Таким образом, эксперимент E_1 демонстрирует:

- устойчивую сходимость ГА за ограниченное число поколений;
- способность алгоритма учитывать вариации входных данных (параметрическая неопределенность).

3.6.2. Описание и результаты эксперимента E_2 . Для оценки преимуществ предложенного модифицированного ГА в сравнении с классическим ГА (К-ГА) была выполнена серия из тридцати независимых вычислительных экспериментов. В каждом запуске идентичный номинальный набор исходных данных подвергался стохастическому возмущению: координаты роботов и заданий искажались равномерными отклонениями $\pm 0,5$ ед., а удельные энергозатраты – отклонениями $\pm 0,3$ ед. В обоих алгоритмах размеры популяции и параметры эволюционных операторов совпадали.

Результаты показаны в таблице 7 и на рисунках 5 и 6. Как видно, во всех основных точечных и интервальных статистиках – среднем, медиане, квантилях, а также в минимальном и максимальном значениях – модифицированный ГА демонстрирует более низкую (то есть более выгодную) стоимость распределения задач.

Таблица 7. Сравнение с К-ГА ($n = 30$)

Показатели эффективности	К-ГА	Модифицированный ГА
Среднее значение целевой функции J , усл. ед.	20.68 ± 4.53	20.35 ± 4.59
Медиана, усл. ед.	20.72	19.77
10-я квантиль, усл. ед.	15.31	14.80
90-я квантиль, усл. ед.	27.62	27.45
Минимум, усл. ед.	13.77	13.37
Максимум, усл. ед.	30.04	29.64
Поколение стабилизации решения g	1.0 ± 0.0	1.0 ± 0.0
СРУ-время, с	0.18 ± 0.06	0.58 ± 0.01




Рис. 5. Распределение целевой функции за 30 запусков




Рис. 6. Средняя динамика сходимости

По полученным результатам можно сделать следующие выводы:

1. Модифицированный ГА обеспечил снижение среднего значения целевой функции $J(8)$ примерно на 7 %, а верхний квантиль 90 % – на 8 % по сравнению с К-ГА.

2. Рост времени вычислений связан с тройной оценкой каждой особи и остается приемлемым для задач оперативного планирования: $< 0,6$ с на указанной аппаратной платформе.

3. Снижение $J(8)$ эквивалентно экономии суммарной энергии группы роботов и позволяет получить прирост автономности, что особенно важно при длительных автономных миссиях.

3.6.3. Выводы. В первом эксперименте показано, что модифицированный генетический алгоритм стабильно работает в условиях параметрической неопределенности: он сохраняет корректность распределения, быстро сходится и демонстрирует приемлемые значения целевой функции $J(8)$ при возмущениях входных данных. Во втором эксперименте установлено, что модифицированный генетический алгоритм статистически снижает целевой показатель $J(8)$ при умеренном росте вычислительных затрат и является более предпочтительным для распределения заданий в условиях параметрической неопределенности, чем классическая схема ГА. В то же время следует помнить, что требуются дополнительные вычислительные ресурсы, что может быть ограничением при работе в реальном времени.

В целом предложенный модифицированный ГА улучшает критерий энергопотребления и может быть рекомендован для практического применения в задачах распределения заданий между мобильными роботами в неопределенной среде.

4. Сравнительный анализ предложенных алгоритмов и рекомендации по их применению в условиях неопределенности. На основе результатов численных экспериментов (разделы 3.2–3.6) составлена сводная характеристика трех модифицированных подходов: муравьиного алгоритма (МА), нейронной сети Хопфилда (НС) и генетического алгоритма (ГА). Для сравнения были использованы следующие критерии:

- устойчивость к неопределенности (сохранение качества при увеличении шума);
- гибкость настройки (число параметров, влияющих на результат);
- сходимость (среднее число итераций до стабилизации решения);
- интерпретируемость (степень прозрачности механизма принятия решения);

- объем вычислений (оценка времени вычислений для различных n);
- способность к адаптации (возможность подстраивать алгоритм под изменения условий).

Сводные результаты приведены в таблице 8.

Оценки основаны на результатах из таблиц 2, 5 и 7: например, НС обеспечила снижение суммарной длины маршрутов на 18 %, а ГА – снижение целевого показателя J на 7 % относительно классических вариантов.

Таблица 8. Сравнительная характеристика МА, НС и ГА

Критерий	МА	НС	ГА
Устойчивость к неопределенности	Средняя	Высокая	Высокая
Гибкость настройки	Высокая	Ограниченная	Высокая
Сходимость	Быстрая при хорошей инициализации	Быстрая для малых задач	Умеренная
Интерпретируемость	Средняя	Высокая (энергетическая функция)	Средняя
Объем вычислений	Средний (до $n = 10$)	Низкий	Средний – высокий (при $n > 10$)
Способность к адаптации	Высокая	Ограниченная	Высокая

На основе проведенного анализа разработаны следующие рекомендации по выбору метода:

1. Использовать МА в детерминированных сценариях с известной топологией и большим числом узлов.
2. Использовать НС в случаях, когда необходима высокая интерпретируемость и низкие вычислительные затраты ($n \leq 10$).
3. Рекомендуется использовать ГА в динамичной стохастической среде и при необходимости быстрой адаптации параметров.
4. При высокой изменчивости условий среды целесообразно комбинировать МА или ГА с НС в рамках гибридной архитектуры – это повышает устойчивость решения.

4.1. Масштабируемость алгоритмов. Несмотря на то, что численные эксперименты в работе выполнены для диапазона

$$n \leq 20, m \leq 40,$$

асимптотическая сложность сохраняется на уровне $O(m \cdot \log m)$ (при фиксированном n), что совпадает с базовой оценкой для классических вариантов МА и ГА [14, 17]. В литературе приводятся успешные применения этих алгоритмов при $n, m \geq 100$ [1, 24], а предложенные модификации не приводят к увеличению теоретической трудоемкости алгоритмов. Следовательно, при условии пропорционального увеличения вычислительных ресурсов результаты остаются переносимыми и на большие группы роботов. В реальных промышленных системах обычно применяют иерархическую декомпозицию, когда набор заданий разбивается на кластеры. Такой прием является прямым направлением дальнейших исследований и выходит за рамки текущей статьи.

5. Заключение. В данной работе разработаны модифицированные версии трех эвристических алгоритмов распределения заданий для групп мобильных роботов и выполнен их анализ. Численные эксперименты показали:

1. Адаптивный муравьиный алгоритм уменьшает суммарную длину маршрутов на 15–20 % по сравнению с базовым.
2. Модифицированная сеть Хопфилда уменьшает суммарную длину маршрутов примерно на 18 % и обеспечивает лучшую воспроизводимость результатов.
3. Генетический алгоритм снижает интегральный критерий J на 7 % при умеренном увеличении времени вычислений.

Учет параметрической и стохастической неопределенности несколько увеличивает вычислительные затраты, однако повышает устойчивость и практическую применимость решений. Полученные результаты могут быть использованы при проектировании интеллектуальных систем группового управления, функционирующих в условиях неполноты информации и ограниченных ресурсов. Предложенные подходы могут быть применены и для решения других задач, однако для этого потребуется их адаптация к специфическим условиям соответствующих приложений.

В дальнейшем планируется решить следующие задачи: интеграция рассмотренных методов в гибридную архитектуру распределения; расширенные испытания на больших группах роботов ($n > 20$); учет временных ограничений и приоритетов заданий.

Литература

1. Lin X., Gao F., Bian W. A high-effective swarm intelligence-based multi-robot cooperation method for target searching in unknown hazardous environments // Expert Systems with Applications. 2025. vol. 262. DOI: 10.1016/j.eswa.2024.125609.

2. Cardona G.A., Calderon J.M. Robot Swarm Navigation and Victim Detection Using Rendezvous Consensus in Search and Rescue Operations // *Applied Sciences*. 2019. vol. 9(8). DOI: 10.3390/app9081702.
3. Alotaibi E.T., Alqefari S.S., Koubaa A. LSAR: Multi-UAV Collaboration for Search and Rescue Missions // *IEEE Access*. 2019. vol. 7. pp. 55817–55832. DOI: 10.1109/ACCESS.2019.2912306.
4. Cao Y.U., Fukunaga A.S., Kahng A. Cooperative mobile robotics: Antecedents and directions // *Autonomous Robots*. 1997. vol. 4. pp. 7–27.
5. Gerkey B.P., Mataric M.J. A Formal Analysis and Taxonomy of Task Allocation in Multi-Robot Systems // *International Journal of Robotics Research*. 2004. vol. 23(9). pp. 939–954. DOI: 10.1177/027836490404045564.
6. Kalyaev I.A., Melnik E.S., Klimenko A.V. Distributed Ledger Based Workload Logging in the Robot Swarm // *Proc. 4th Int. Conf. Interactive Collaborative Robotics (ICR 2019)*. LNCS, 2019. pp. 119–128. DOI: 10.1007/978-3-030-26118-4_12.
7. Kalyaev I.A. Melnik E.S., Klimenko A.V. Distributed Methods for Autonomous Robot Groups Fault-Tolerant Management // *Proc. 5th Int. Conf. Interactive Collaborative Robotics (ICR 2020)*. LNCS, 2020. vol. 12336. pp. 135–147. DOI: 10.1007/978-3-030-60337-3_14.
8. Brambilla M., Ferrante E., Birattari M., Dorigo M. Swarm robotics: a review from the swarm engineering perspective // *Swarm Intelligence*. 2013. vol. 7. pp. 1–41. DOI: 10.1007/s11721-012-0075-2.
9. Parker L.E. ALLIANCE: An Architecture for Fault Tolerant Multi-Robot Cooperation // *IEEE Transactions on Robotics and Automation*. 1998. vol. 14(2). pp. 220–240. DOI: 10.1109/70.681242.
10. Dadgar E., Jafari S., Hamzeh A. A PSO-based multi-robot cooperation method for target searching in unknown environments // *Neurocomputing*. 2016. vol. 177. pp. 62–74. DOI: 10.1016/j.neucom.2015.11.007.
11. Garg R. E2RGWO: Exploration enhanced robotic Grey Wolf Optimizer for cooperative multiple target search for robotic swarms // *Arabian Journal for Science and Engineering*. 2023. vol. 48. pp. 9887–9903. DOI: 10.1007/s13369-022-07438-5.
12. Dorri A., Kanhere S.S., Jurdak R. Multi-Agent Systems: A Survey // *IEEE Access*. 2018. vol. 6. pp. 28573–28593. DOI: 10.1109/ACCESS.2018.2831228.
13. Fox D., Ko J., Konolige K., Limketkai B., Schulz D., Stewart B. Distributed multirobot exploration and mapping // *Proceedings of the IEEE*. 2006. vol. 94(7). pp. 1325–1339. DOI: 10.1109/JPROC.2006.876927.
14. Dorigo M., Blum C., Stutzle T. Ant Colony Optimization – Introduction and Recent Trends // *IEEE Computational Intelligence Magazine*. 2007. vol. 1(4). pp. 28–39. DOI: 10.1109/MCI.2006.329691.
15. Liu F., Tan Y. Multi-robot Task Allocation Based on Ant Colony Algorithm // *Journal of Computers*. 2012. vol. 7(9). pp. 2160–2167.
16. Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities // *Proceedings of the National Academy of Sciences USA*. 1982. vol. 79(8). pp. 2554–2558. DOI: 10.1073/pnas.79.8.2554.
17. Cecchin A.K., De Pieri E.R., Pérez A.L.F., Plentz P.D.M. Multi-robot Task Allocation Using Island Model Genetic Algorithm // *IFAC-PapersOnLine*. 2021. vol. 54(1). pp. 558–563. DOI: 10.1016/j.ifacol.2021.08.063.
18. Darintsev O.V., Migranov A.B. Multi-criteria Optimization of the Mobile Robot Group Strategy Using the Ant Algorithm // *Eds.: Ronzhin A., Shishlakov V. Electromechanics and Robotics. Smart Innovation. Systems and Technologies*. Springer. Singapore. 2022. vol. 232. pp. 97–108. DOI: 10.1007/978-981-16-2814-6_9.
19. Даринцев О.В., Мигранов А.Б. Модификация аппарата нейронной сети Хопфилда для решения задачи оптимального распределения заданий в группе

- мобильных роботов // Известия РАН. Теория и системы управления. 2024. № 2. С. 169–182.
20. Darintsev O.V., Migranov A.B. Task Distribution Module for a Team of Robots Based on Genetic Algorithms: Synthesis Methodology and Testing // Proc. XXI Int. Conf. Complex Systems: Control and Modeling Problems (CSCMP). 2019. pp. 296–300. DOI: 10.1109/CSCMP45713.2019.8976649.
21. Khamis A.M., Hussein A., Elmogay A.M. Multi-robot Task Allocation: A Review of the State-of-the-Art // Eds. Koubâa A., Martínez-de-Dios J.R. Cooperative Robots and Sensor Networks. Studies in Computational Intelligence. Springer. Cham. 2015. pp. 31–51. DOI: 10.1007/978-3-319-18299-5_2.
22. Dias M.B., Zlot R., Kalra N., Stentz A. Market-based multirobot coordination: A survey and analysis // Proceedings of the IEEE. 2006. vol. 94(7). pp. 1257–1270. DOI: 10.1109/JPROC.2006.876939.
23. Garg R., Shukla A., Tiwari R. AERPSO – An adaptive exploration robotic PSO based cooperative algorithm for multiple target searching // Expert Systems with Applications. 2022. vol. 209. DOI: 10.1016/j.eswa.2022.118245.
24. Zhu B., Xie W.-F. An improved genetic algorithm with Euclidean geometry and hybrid heuristic crossover for the traveling salesman problem // 2023 IEEE Congress on Evolutionary Computation (CEC). Chicago, IL, USA, 2023. pp. 1–8. DOI: 10.1109/CEC53210.2023.10254179.
25. Fan M., Li J. Surrogate-assisted genetic algorithms for the travelling salesman problem and vehicle routing problem // Proc. IEEE Congress on Evolutionary Computation (CEC). 2020. pp. 1–7. DOI: 10.1109/CEC48606.2020.9185817.
26. Ojeda Rios B.H., Xavier E.C., Miyazawa F., Amorim P., Curcio E., Joao Santos M. Recent dynamic vehicle routing problems: A survey // Computers & Industrial Engineering. 2021. vol. 160. DOI: 10.1016/j.cie.2021.107604.
27. Ding H., Cheng H.-J., Shan X. Modified Artificial Bee Colony Algorithm for the Capacitated Vehicle Routing Problem // DEStech Transactions on Social Science, Education and Human Science. 2018. DOI: 10.12783/dtssehs/amse2018/24837.
28. Gendreau M., Hertz A., Laporte G. A tabu search heuristic for the vehicle routing problem // Management Science. 1994. vol. 40(10). pp. 1276–1290. DOI: 10.1287/mnsc.40.10.1276.
29. Kirkpatrick S., Gelatt C.D., Vecchi M.P. Optimization by simulated annealing // Science. 1983. vol. 220(4598). pp. 671–680. DOI: 10.1126/science.220.4598.671.
30. Даринцев О.В., Мигранов А.Б. Аналитический обзор подходов к распределению задач в группах мобильных роботов на основе технологий мягких вычислений // Информатика и автоматизация. 2022. Т. 21. № 4. С. 729–757.
31. Chao I.M., Golden B.L., Wasil E.A. A new heuristic for the multi-depot vehicle routing problem that improves upon best-known solutions // American Journal of Mathematical and Management Sciences. 1993. vol. 13(3–4). pp. 371–406. DOI: 10.1080/01966324.1993.10737363.
32. Dorigo M., Stützle T. Ant Colony Optimization, MIT Press, 2004.

Мигранов Айрат Барисович — канд. техн. наук, старший научный сотрудник, лаборатория «робототехника и управление в технических системах», ИМех УФИЦ РАН. Область научных интересов: робототехника, искусственный интеллект. Число научных публикаций — 145. abm.imech.anrb@mail.ru; проспект Октября, 71, 450054, Уфа, Россия; р.т.: +7(347)225-5255.

Поддержка исследований. Работа выполнена в рамках госзадания FMRS-2023-0016 (123020700078-8).

A. MIGRANOV

**MODIFIED HEURISTIC TASK ALLOCATION ALGORITHMS
FOR MOBILE ROBOT TEAMS UNDER UNCERTAINTY**

Migranov A. Modified Heuristic Task Allocation Algorithms for Mobile Robot Teams under Uncertainty.

Abstract. This study addresses the problem of task allocation among groups of mobile robots under conditions of parametric and stochastic uncertainty arising from sensor errors, environmental non-stationarity, and limited information about controlled objects. The primary objective is to adapt previously developed heuristic algorithms to real-world conditions, where sensor inaccuracies and incomplete knowledge of the environment are present. Three baseline approaches are considered: the ant colony algorithm, the Hopfield neural network, and the genetic algorithm. Each method is enhanced with specific modifications to account for input uncertainty: dynamic pheromone trail updates, adaptive adjustment of neuron weight coefficients, and interval-based estimation of environmental parameters. The paper presents a formal problem statement, mathematical models, and the design principles of the proposed task allocation algorithms. Numerical simulations were conducted to compare the performance of the modified algorithms against their baseline counterparts under varying levels of operational uncertainty. Results show that the proposed adaptive mechanisms improve task allocation efficiency by up to 20% compared to the original methods. Based on these findings, recommendations are formulated for selecting the optimal algorithm depending on specific operating conditions and control objectives. The study concludes that the proposed approaches are effective for the design of intelligent adaptive group control systems for mobile robots. Furthermore, these solutions can be extended to a broader class of problems, including dynamic resource reassignment and the organization of cooperative behavior among technical agents.

Keywords: task allocation, heuristic algorithms, mobile robot teams, ant colony algorithm, Hopfield neural network, genetic algorithm.

References

1. Lin X., Gao F., Bian W. A high-effective swarm intelligence-based multi-robot cooperation method for target searching in unknown hazardous environments. *Expert Systems with Applications*. 2025. vol. 262. DOI: 10.1016/j.eswa.2024.125609.
2. Cardona G.A., Calderon J.M. Robot Swarm Navigation and Victim Detection Using Rendezvous Consensus in Search and Rescue Operations. *Applied Sciences*. 2019. vol. 9(8). DOI: 10.3390/app9081702.
3. Alotaibi E.T., Alqefari S.S., Koubaa A. LSAR: Multi-UAV Collaboration for Search and Rescue Missions. *IEEE Access*. 2019. vol. 7. pp. 55817–55832. DOI: 10.1109/ACCESS.2019.2912306.
4. Cao Y.U., Fukunaga A.S., Kahng A. Cooperative mobile robotics: Antecedents and directions. *Autonomous Robots*. 1997. vol. 4. pp. 7–27.
5. Gerkey B.P., Mataric M.J. A Formal Analysis and Taxonomy of Task Allocation in Multi-Robot Systems. *International Journal of Robotics Research*. 2004. vol. 23(9). pp. 939–954. DOI: 10.1177/0278364904045564.
6. Kalyaev I.A., Melnik E.S., Klimenko A.V. Distributed Ledger Based Workload Logging in the Robot Swarm. *Proc. 4th Int. Conf. Interactive Collaborative Robotics (ICR 2019)*. LNCS, 2019. pp. 119–128. DOI: 10.1007/978-3-030-26118-4_12.

7. Kalyaev I.A. Melnik E.S., Klimenko A.V. Distributed Methods for Autonomous Robot Groups Fault-Tolerant Management. Proc. 5th Int. Conf. Interactive Collaborative Robotics (ICR 2020). LNCS, 2020. vol. 12336. pp. 135–147. DOI: 10.1007/978-3-030-60337-3_14.
8. Brambilla M., Ferrante E., Birattari M., Dorigo M. Swarm robotics: a review from the swarm engineering perspective. *Swarm Intelligence*. 2013. vol. 7. pp. 1–41. DOI: 10.1007/s11721-012-0075-2.
9. Parker L.E. ALLIANCE: An Architecture for Fault Tolerant Multi-Robot Cooperation. *IEEE Transactions on Robotics and Automation*. 1998. vol. 14(2). pp. 220–240. DOI: 10.1109/70.681242.
10. Dadgar E., Jafari S., Hamzeh A. A PSO-based multi-robot cooperation method for target searching in unknown environments. *Neurocomputing*. 2016. vol. 177. pp. 62–74. DOI: 10.1016/j.neucom.2015.11.007.
11. Garg R. E2RGWO: Exploration enhanced robotic Grey Wolf Optimizer for cooperative multiple target search for robotic swarms. *Arabian Journal for Science and Engineering*. 2023. vol. 48. pp. 9887–9903. DOI: 10.1007/s13369-022-07438-5.
12. Dorri A., Kanhere S.S., Jurdak R. Multi-Agent Systems: A Survey. *IEEE Access*. 2018. vol. 6. pp. 28573–28593. DOI: 10.1109/ACCESS.2018.2831228.
13. Fox D., Ko J., Konolige K., Limketkai B., Schulz D., Stewart B. Distributed multirobot exploration and mapping. *Proceedings of the IEEE*. 2006. vol. 94(7). pp. 1325–1339. DOI: 10.1109/JPROC.2006.876927.
14. Dorigo M., Blum C., Stutzle T. Ant Colony Optimization – Introduction and Recent Trends. *IEEE Computational Intelligence Magazine*. 2007. vol. 1(4). pp. 28–39. DOI: 10.1109/MCI.2006.329691.
15. Liu F., Tan Y. Multi-robot Task Allocation Based on Ant Colony Algorithm. *Journal of Computers*. 2012. vol. 7(9). pp. 2160–2167.
16. Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences USA*. 1982. vol. 79(8). pp. 2554–2558. DOI: 10.1073/pnas.79.8.2554.
17. Cechinel A.K., De Pieri E.R., Pérez A.L.F., Plentz P.D.M. Multi-robot Task Allocation Using Island Model Genetic Algorithm. *IFAC-PapersOnLine*. 2021. vol. 54(1). pp. 558–563. DOI: 10.1016/j.ifacol.2021.08.063.
18. Darintsev O.V., Migranov A.B. Multi-criteria Optimization of the Mobile Robot Group Strategy Using the Ant Algorithm. Eds.: Ronzhin A., Shishlakov V. *Electromechanics and Robotics. Smart Innovation. Systems and Technologies*. Springer. Singapore. 2022. vol. 232. pp. 97–108. DOI: 10.1007/978-981-16-2814-6_9.
19. Darincev O.V., Migranov A.B. [Modification of the Hopfield Neural Network Framework for Solving the Task Allocation Problem in a Mobile Robot Team]. *Izvestiya RAN. Teoriya i sistemy upravleniya*. [Izvestiya RAN. Theory and Control Systems]. 2024. no. 2. pp. 169–182. (In Russ.).
20. Darintsev O.V., Migranov A.B. Task Distribution Module for a Team of Robots Based on Genetic Algorithms: Synthesis Methodology and Testing. Proc. XXI Int. Conf. Complex Systems: Control and Modeling Problems (CSCMP). 2019. pp. 296–300. DOI: 10.1109/CSCMP45713.2019.8976649.
21. Khamis A.M., Hussein A., Elmogy A.M. Multi-robot Task Allocation: A Review of the State-of-the-Art. Eds. Koubâa A., Martínez-de-Dios J.R. *Cooperative Robots and Sensor Networks. Studies in Computational Intelligence*. Springer. Cham. 2015. pp. 31–51. DOI: 10.1007/978-3-319-18299-5_2.
22. Dias M.B., Zlot R., Kalra N., Stentz A. Market-based multirobot coordination: A survey and analysis. *Proceedings of the IEEE*. 2006. vol. 94(7). pp. 1257–1270. DOI: 10.1109/JPROC.2006.876939.

23. Garg R., Shukla A., Tiwari R. AERPSO – An adaptive exploration robotic PSO based cooperative algorithm for multiple target searching. *Expert Systems with Applications*. 2022. vol. 209. DOI: 10.1016/j.eswa.2022.118245.
24. Zhu B., Xie W.-F. An improved genetic algorithm with Euclidean geometry and hybrid heuristic crossover for the traveling salesman problem. *2023 IEEE Congress on Evolutionary Computation (CEC)*. Chicago, IL, USA, 2023. pp. 1-8. DOI: 10.1109/CEC53210.2023.10254179.
25. Fan M., Li J. Surrogate-assisted genetic algorithms for the travelling salesman problem and vehicle routing problem. *Proc. IEEE Congress on Evolutionary Computation (CEC)*. 2020. pp. 1–7. DOI: 10.1109/CEC48606.2020.9185817.
26. Ojeda Rios B.H., Xavier E.C., Miyazawa F., Amorim P., Curcio E., Joao Santos M. Recent dynamic vehicle routing problems: A survey. *Computers & Industrial Engineering*. 2021. vol. 160. DOI: 10.1016/j.cie.2021.107604.
27. Ding H., Cheng H.-J., Shan X. Modified Artificial Bee Colony Algorithm for the Capacitated Vehicle Routing Problem. *DEStech Transactions on Social Science, Education and Human Science*. 2018. DOI: 10.12783/dtssehs/amse2018/24837.
28. Gendreau M., Hertz A., Laporte G. A tabu search heuristic for the vehicle routing problem. *Management Science*. 1994. vol. 40(10). pp. 1276–1290. DOI: 10.1287/mnsc.40.10.1276.
29. Kirkpatrick S., Gelatt C.D., Vecchi M.P. Optimization by simulated annealing. *Science*. 1983. vol. 220(4598). pp. 671–680. DOI: 10.1126/science.220.4598.671.
30. Darincev O.V., Migranov A.B. [Analytical Review of Task Allocation Approaches in Mobile Robot Teams Based on Soft Computing Technologies]. *Informatika i avtomatizacija. [Informatics and Automation]*. 2022. vol. 21. no. 4. pp. 729–757. (In Russ.).
31. Chao I.M., Golden B.L., Wasil E.A. A new heuristic for the multi-depot vehicle routing problem that improves upon best-known solutions. *American Journal of Mathematical and Management Sciences*. 1993. vol. 13(3–4). pp. 371–406. DOI: 10.1080/01966324.1993.10737363.
32. Dorigo M., Stützle T. *Ant Colony Optimization*, MIT Press, 2004.

Migranov Ayrat — Ph.D., Senior researcher, Laboratory of «robotics and control in technical systems», Mavlyutov Institute of Mechanics, Ufa Federal Research Centre, Russian Academy of Sciences. Research interests: robotics, artificial intelligence. The number of publications — 145. abm.imech.anrb@mail.ru; 71, Oktyabrya Av., 450054, Ufa, Russia; office phone: +7(347)225-5255.

Acknowledgements. This work was carried out within the framework of the state assignment FMRS-2023-0016 (123020700078-8).

В.А. БОГАТЫРЕВ, В. ФУНГ
**ПРИБЛИЖЕННАЯ ОЦЕНКА ЗАДЕРЖЕК В КОМПЬЮТЕРНОЙ
СИСТЕМЕ С КОНТЕЙНЕРНОЙ ВИРТУАЛИЗАЦИЕЙ**

Богатырев В.А., Фунг В. Приближенная оценка задержек в компьютерной системе с контейнерной виртуализацией.

Аннотация. Ключевую роль в достижении высокой надежности, безопасности, отказоустойчивости и малых задержек обслуживания запросов в распределенных системах (в том числе облачных вычислений) играет консолидация ресурсов обработки и хранения данных в кластерах, эффективность которых повышается при использовании технологий виртуальных машин и контейнерной виртуализации. Сложность построения моделей массового обслуживания систем контейнерной виртуализации вызвана тем, что интенсивность выполнения запросов в каждом контейнере связана с динамическим разделением общих ресурсов между активными (выполняющими функциональные задачи) контейнерами и издержками на поддержку всех развернутых в виртуальной машине контейнеров, в том числе неактивных, ожидающих направления в них запросов для обслуживания. Снижение интенсивности обслуживания в каждом контейнере из-за совместного использования общих ресурсов зависит от многих трудно исследуемых факторов. Для кластеров с контейнерной виртуализацией в данной статье предлагается приближенная граничная оценка среднего времени ожидания запросов и вероятности их своевременного обслуживания. При построении аналитической модели каждый контейнер представляется как отдельная одноканальная система массового обслуживания с бесконечной очередью и простейшим входным потоком. Основное отличие предлагаемой модели виртуального кластера заключается в граничной верхней, нижней и усредненной оценке возможного снижения интенсивности обслуживания в контейнерах из-за разделения между ними общих ограниченных вычислительных ресурсов узла кластера в зависимости от количества развернутых в нем контейнеров и изменяющегося числа активных контейнеров, зависящего от интенсивности входного потока. Показано существование оптимального числа развернутых в узлах контейнеров, при котором среднее время пребывания запросов в системе минимально, либо вероятность выполнения запросов за заданное время максимальна. Предлагаемые модели могут быть применены при структурно-параметрической оптимизации кластеров с конвейерной виртуализацией, в том числе в случае масштабирования и реконфигурации, адаптивной к и изменениям трафика, путем отключения или подключения части развернутых контейнеров в зависимости от изменений нагрузки в системе.

Ключевые слова: контейнер, контейнерная виртуализация, кластер, разделение ресурсов, задержка.

1. Введение. В настоящее время для распределенных компьютерных систем, в том числе облачных вычислений, все более критичными становятся требования их безопасности, надежности, отказоустойчивости [1 – 4] и производительности [5]. Ключевую роль в достижении этих требований играет консолидация ресурсов обработки и хранения данных в кластерах, эффективность которых

повышается при использовании технологий виртуальных машин и контейнеров.

Виртуальные машины (ВМ) [6 – 8] эмулируют полноценные компьютеры в виртуальной среде, при этом каждая ВМ включает в себя собственные выделяемые аппаратные средства, такие как процессор, память, сетевые интерфейсы и дисковое пространство. ВМ могут применяться для запуска различных операционных систем и приложений на одном физическом сервере. Это позволяет эффективно использовать вычислительные ресурсы и обеспечивает логическую изоляцию ВМ, что способствует повышению информационной безопасности компьютерной системы [9].

Применение виртуальных машин в облачных системах обеспечивает максимальную эффективность использования ресурсов. Платформы, такие как VMWare, OpenStack, Proxmox и другие, позволяют поставщикам облачных услуг предоставлять клиентам независимые виртуальные машины, адаптируемые под их конкретные потребности и требуемые ресурсы. Вместе с тем клиенты могут разворачивать свои приложения в контейнерах, работающих на физических серверах или виртуальных машинах, предоставляемых облачными поставщиками.

Технология виртуальных контейнеров стимулировала развитие микросервисной архитектуры, при которой приложения разделяются на небольшие, независимые сервисы, взаимодействующие через хорошо определённые программные интерфейсы приложений (API – Application Programming Interface). Такой подход потенциально позволяет повысить устойчивость функционирования к отказам системы, так как отказ (сбой) одного или нескольких микросервисов может не приводить к выходу из строя всего приложения, хотя в ряде случаев может вызвать частичную потерю функциональности. Использование микросервисной архитектуры способствует простоте реконфигурации, масштабирования и модернизации системы.

Технологии виртуализации, предоставляют мощные инструменты для обеспечения как надежности, так и информационной безопасности компьютерной системы, при этом в результате логической изоляции приложений и сервисов в виртуальных средах риск воздействия одного компонента на другой может быть минимизирован. Таким образом, виртуализация позволяет ускорить восстановление работоспособности системы в случае отказов, сбоев или злонамеренных воздействий при атаках.

Изоляция у контейнеров менее строгая, чем у виртуальных машин, что требует применения дополнительных мер для обеспечения

их безопасности. Повышению безопасности способствует использование минимальных базовых образов при контейнерной виртуализации, а также регулярное обновление операционной системы.

Реконфигурация отказоустойчивых систем при виртуализации связана с необходимостью репликации и миграции виртуальных машин, а также развертывания реплик контейнеров при необходимости [10, 11]. Построение отказоустойчивых кластеров (включая кластеры с контейнерной виртуализацией), требует обоснования и оптимизации решений обеспечения надежности, производительности кластера и высокоскоростного надежного доступа к нему через коммуникационную среду, которая используется также для миграции виртуальных машин при реконфигурации системы [12 – 14].

Важными составляющими обоснования выбора структуры, функциональной организации и правил эксплуатации кластера является оптимизация дисциплин: диспетчеризации и распределения запросов при балансировке нагрузки; физического и информационного восстановления системы после отказов и сбоев; обеспечения непрерывности вычислений и устойчивости к потере данных. При этом отметим взаимозависимости перечисленных дисциплин, требующих оптимизации. Оптимизация кластера требует построения взаимосвязанных моделей его надежности и обслуживания трафика.

Выбор решений по оптимизации кластера с контейнерной виртуализацией осложняется необходимостью учета при моделировании динамического разделения и совместного использования ограниченных вычислительных ресурсов системы между виртуальными машинами и контейнерами. Для отказоустойчивого функционирования требуется выделение общих ресурсов системы для процессов контроля и реконфигурации, включая формирование реплик и миграцию виртуальных машин и контейнеров при обнаружении отказов.

Адаптивная реконфигурация, предусматривающая создание дополнительных реплик контейнеров или их удаление, может быть выполнена в зависимости от изменения интенсивности трафика. При этом важно учитывать компромисс между задержками обслуживания запросов, производительностью, надежностью и энергопотреблением системы.

Эффективное решение задач реконфигурации должно базироваться на концепции модельно-ориентированного проектирования с использованием моделей надежности и массового

обслуживания. При построении отказоустойчивых кластеров необходимо учитывать взаимное влияние мероприятий и механизмов, направленных на обеспечение надежности и производительности, и находить компромисс при выборе проектных решений.

В кластерах, предусматривающих совместную работу множества виртуальных машин и контейнеров, важно понимать, как отказы отдельных компонентов могут влиять на общую производительность и задержки обслуживания потоков запросов.

На оценку задержек и других вероятностно-временных показателей качества функционирования компьютерных систем ориентирован аппарат теории массового обслуживания [15 – 17]. Модели обслуживания кластерных систем на базе виртуальных машин, размещаемых на физических узлах кластера, в том числе в облачной среде, предложены в работах [18 – 20]. Известные модели кластеров виртуальных машин учитывают балансировку нагрузки узлов (виртуальных машин), проводимую при диспетчеризации запросов. Модели, отражающие работу кластеров в нестационарных режимах обслуживания при периодических изменениях во времени трафика запросов, описаны в статьях [21 – 23]. Периодичность изменения трафика вызвана его повторяющимися колебаниями в течение суток, дней недели, месяца и года.

При проектировании компьютерных систем кластерной архитектуры важен анализ совокупного влияния отказов и дисциплин физического и информационного восстановления на надежность и задержки обслуживания. При обосновании выбора кластерных систем важна разработка критериев, учитывающих обеспечение высоких уровней надежности, производительности и доступности (готовности) системы [24, 25].

Для современных концепций построения отказоустойчивых кластеров на основе виртуальных машин с размещением в них контейнеров важной задачей является анализ задержек обслуживания поступающего потока запросов [26], с учетом особенностей контейнерной виртуализации, заключающейся в автоматическом разделении ограниченных ресурсов виртуальной машины между активными контейнерами. Модели кластеров [18 – 26] не учитывают особенностей контейнерной виртуализации.

Модели оценки задержек систем с контейнерной виртуализацией для однородного потока запросов без учета задержек их распределения по узлам и балансировки нагрузки рассматривались в [27 – 29]. В работе [30] предложена модель оценки задержек в кластере виртуальных машин, компонуемых контейнерами с учетом

двух этапов распределения запросов. Модель [30] учитывает задержки в очереди балансировщика нагрузки кластера при распределении запросов между узлами кластера, каждый из которых содержит группу виртуальных машин. Модель [30] учитывает также задержки в очередях для каждой группы виртуальных машин, компонуемых контейнерами. На основе предложенной в [30] аналитической модели проанализировано влияние числа развернутых в виртуальной машине контейнеров на время отклика системы по выполнению запросов, однако влияние соотношения числа развернутых и активных контейнеров при этом не учитывается (не установлено). Результаты статьи [30] могут быть использованы при обосновании выбора конфигурации кластера, включая определение оптимального числа разворачиваемых в узлах контейнеров. Ограниченность модели СМО работы [30], в которой рассматривается кластер, состоящий из нескольких серверов, на каждом из которых развернуто несколько контейнеров, обусловлена предположением независимости каждого канала обслуживания, представляющего отдельный контейнер. Динамическое изменение интенсивности обслуживания в разных каналах в зависимости от доли загруженных (активных) каналов при этом не учитывалось.

Влияние числа разворачиваемых в узлах кластера контейнеров на среднее время ожидания и устойчивость облачных вычислений к DDoS атакам исследовано в [9]. Результаты статьи [9], подтвержденные аналитическим моделированием и экспериментальными исследованиями, могут быть применены при динамической реконфигурации систем в зависимости от интенсивности DDoS атак, направленных на нарушение стационарности обслуживания потока легальных запросов и их потерю.

Ограниченность существующих моделей кластеров с контейнерной виртуализацией обусловлена недостаточностью исследований влияния на задержки обслуживания запросов динамического разделения ограниченных вычислительных ресурсов между простаивающими контейнерами и контейнерами, выполняющими функциональные запросы. Такая особенность совместной работы виртуальных контейнеров вызывает усложнение моделей массового обслуживания, так как интенсивность выполнения запросов в каждом контейнере связана с динамическим разделением общих ресурсов между активными (выполняющими функциональные задачи) контейнерами с учетом издержек на поддержку всех развернутых в виртуальной машине контейнеров (активных и

простаивающих). Снижение интенсивности обслуживания в каждом контейнере из-за совместного использования общих ресурсов зависит от многих трудно исследуемых факторов, в том числе от частоты и длительности обращения контейнеров во время обслуживания запроса к тем или иным ресурсам процессоров и памяти. Разделение общих вычислительных ресурсов зависит от наличия интервалов простоев при таких обращениях, во время которых общие ресурсы потенциально могут использоваться другими активными контейнерами. Такое адаптивное разделение общих ресурсов несомненно способствует эффективности их совместного использования и минимизации простоев в результате предоставления ресурсов для работы других активных контейнеров. Учет перечисленных факторов совместного использования общих ресурсов приводит к трудоемкости построения аналитической модели обслуживания кластерных систем с контейнерной виртуализацией.

При построении аналитической модели массового обслуживания систем с контейнерной виртуализацией в статье [31] предлагается использовать экспериментально установленную зависимость снижения интенсивности обслуживания отдельных контейнеров от числа развернутых в виртуальной машине контейнеров и их активной части, которая изменяется в зависимости от интенсивности потока запросов. Эксперименты, описанные в [31], подтверждают существенное влияние разделения ограниченных вычислительных ресурсов виртуальной машины между активными и развернутыми контейнерами.

При сочетании экспериментальных исследований и аналитического моделирования в статье [31] дана оценка вероятностно-временных показателей качества обслуживания запросов в системах контейнерной виртуализации. В статьях [31, 32] узлы кластера представлены как многоканальные СМО с общей очередью (конечной для [32] и бесконечной для [31]). Показано существование оптимального значения числа разворачиваемых контейнеров в узле кластера, а также сформулирована задача оптимизации этого числа, направленная на снижение задержек обслуживания запросов в таких системах.

Ограничения, предлагаемого в [31, 32] подхода к построению аналитической модели обслуживания кластера с контейнерной виртуализацией, заключается в необходимости проведения достаточно трудоемкого эксперимента в зависимости от изменений среднего времени выполнения запросов для каждого значения числа разворачиваемых в узлах кластера виртуальных контейнеров и их

активного числа, зависящего от интенсивности трафика. Многоканальные СМО [31, 32] ориентированы на системы, в которых к развернутым в каждом узле контейнерам организуется общая очередь. Эти модели не отражают функционирование кластеров с контейнерной виртуализацией, в которых к каждому контейнеру организуется отдельная очередь, а кластер представляется группой одноканальных СМО. Построение таких моделей затруднено из-за того, что разделение ограниченных общих ресурсов кластера между контейнерами приводит к необходимости учета зависимости обслуживания очередей разных СМО, представляющих различные контейнеры. Сложность установления зависимости интенсивности обслуживания в разных одноканальных СМО обусловлено разделением общих ресурсов между разными СМО в зависимости от соотношения числа развернутых и активных контейнеров, меняющемся при изменениях интенсивности входного потока.

Для упрощения моделей кластеров с контейнерной виртуализацией при организации отдельных очередей к каждому контейнеру в данной статье предлагается приближенная граничная оценка среднего времени ожидания запросов и вероятности их своевременного обслуживания.

Построение предлагаемой приближенной аналитической модели предполагает экспериментальное определение зависимости интенсивности обслуживания в отдельных контейнерах от изменяемого числа разворачиваемых контейнеров в узле кластера и их числа, участвующих в выполнении функциональных запросов (активных контейнеров). Число активных контейнеров зависит от интенсивности трафика запросов. Экспериментально полученные данные о интенсивности обслуживания в контейнере с учетом динамического разделения ресурсов узла на обслуживание запросов в активных контейнерах предполагается использовать для верхней, нижней и усредненной оценки загрузки контейнеров. Загрузка контейнеров определяется в зависимости от интенсивности входного потока запросов, распределяемых балансировщиком в узел кластера. Результаты аналитической оценки загрузки контейнеров используются для оценки математического ожидания числа контейнеров, задействованных в обработке трафика и математического ожидания интенсивности обслуживания запросов в контейнерах. При определении математического ожидания интенсивности обслуживания запросов в контейнерах используются результаты экспериментов, что позволяет учесть влияние динамического разделения общедоступных ресурсов узла между контейнерами, участвующими и не

участвующими в обслуживании запросов. Полученная приближенная оценка интенсивности обслуживания в контейнерах в дальнейшем используется для вычисления вероятности своевременного обслуживания запросов и их средней задержки в узлах кластера в зависимости от интенсивности поступающих запросов.

Таким образом целью статьи является исследование возможностей повышения эффективности кластерных систем конвейерной виртуализации на основе предлагаемых приближенных граничных моделей для оценок среднего времени пребывания запросов в кластере и вероятности их своевременного обслуживания за время, не превышающее предельно допустимое значение ожидания в очереди.

В качестве целевого критерия эффективности для систем, не требующих выдачи результатов в директивные сроки, используется среднее время пребывания (ожидания) запросов в системе. Для систем с ограниченным допустимым временем ожидания (системы реального времени) в качестве целевой функции используется максимизация вероятности выполнения запросов за время меньшее предельно допустимого.

Оптимальные масштабирование и реконфигурация узлов кластера при изменениях входных потоков реализуется путем отключения или подключения части развернутых в виртуальных машинах контейнеров в зависимости от изменений нагрузки. Отключение части развернутых контейнеров позволяет уменьшить не только энергопотребление кластера, но и снизить загрузку общих ресурсов на поддержку функционирования неактивных контейнеров.

2. Рассматриваемые варианты организации системы с контейнерной виртуализацией. Рассмотрим варианты построения компьютерных систем на базе виртуальных машин с контейнерной виртуализацией. Простейшая организация таких систем, представленная на рисунке 1, включает виртуальную машину с развернутыми в ней n контейнерами. В простейшем случае контейнеры считаются функционально и параметрически одинаковыми, при этом к каждому контейнеру формируется отдельная очередь запросов. Виртуальные машины (рисунок 1), при необходимости, могут объединяться в кластеры на базе одного или нескольких физических узлов (серверов) кластера.

Организация кластера, состоящего из N независимых узлов, реализованных в виде виртуальных машин, каждая из которых содержит n контейнеров, в предположении отсутствия образования очередей в балансировщике нагрузки приведена на рисунке 2, а с

учетом возможности формирования очереди при распределении запросов на рисунке 3.

Особенностью моделируемой системы является то, что интенсивность обслуживания в каждом контейнере изменяется в зависимости от количества развернутых контейнеров и меняющегося числа активных контейнеров, что предполагает зависимость обслуживания запросов в разных контейнерах узла.

На рисунках 1-3 рассматриваемых вариантов систем обозначены: интенсивность входного потока запросов λ , поступающего в каждый узел кластера (виртуальную машину), а также интенсивности входного и выходного потока всего кластера (которые при отсутствии потери запросов в системе совпадают). Следует подчеркнуть, что представленные одноканальные СМО, отличаются от классических, в которых интенсивность обслуживания в каждой СМО не меняется. В системах с виртуальной контейнеризацией общие ресурсы узла динамически разделяются между контейнерами, причем как активными, так и пассивными. Для исследования этого распределения между активными и пассивными контейнерами на интенсивность обслуживания в них запросов в следующем разделе описаны проведенные эксперименты.




Рис. 1. Организация виртуального компьютерного кластера




Рис. 2. Организация кластера N виртуальных машин с контейнеризацией без формирования очереди в балансировщике нагрузки




Рис. 3. Организация кластера виртуальных машин с контейнеризацией при формировании очереди в балансировщике нагрузки

3. Экспериментальное исследование влияния числа активных и общего числа контейнеров в узлах на интенсивность обслуживания в контейнерах. Эксперимент [30, 31] проведен на кластере (рисунок 4), в котором узлы представлены изолированными

виртуальными машинами Proxmox с конфигурацией 1 vCPU и 2 ГБ оперативной памяти, работающими на хосте с 4 процессорами Intel(R) Core(TM) i5-4570 @ 3,20 ГГц. Однопоточный веб-сервер, упакованный в каждый контейнер, написан на языке программирования Python и развёрнут на узлах кластера с использованием платформы k3 s.

Программа внутри веб-сервера включает в себя асинхронную отправку запросов в базу данных и выполнение простых операций умножения матриц в нескольких циклах. Размер кеша составляет 50 МБ.




Рис. 4. Конфигурация системы для реализации эксперимента

В результате эксперимента установлена зависимость интенсивности обслуживания запросов в контейнере $\mu(n, m)$ от числа развернутых контейнеров n и от числа активных контейнеров m (выполняющих обслуживание запросов).

Интенсивности обслуживания, полученные в результате эксперимента, отражены матрицей $\mathbf{M}$. Строки матрицы соответствуют числу развернутых контейнеров n ($n=1, 2, \dots, n_0$, где n_0 максимальное число контейнеров, предусмотренных к разворачиванию в узле), а столбцы числу активных контейнеров m ($m=1, 2, \dots, n$). Таким образом, элемент матрицы $\mathbf{M}$, расположенный в n -й строке и m -м столбце представляет интенсивность обслуживания запросов $\mu(n, m)$ в контейнере, когда в нем развернуто n контейнеров и m из них активно.

и средняя оценка задержек в рассматриваемых системах контейнерной виртуализации.

Следует заметить, что некоторые результаты измерений, могут зависеть от конкретной реализации используемых вычислительных средств и программного обеспечения, а это в отдельных случаях может ограничивать применение модели в новых средах с отличающимися характеристиками. Таким образом, проведение экспериментов для повышения достоверности модели необходимо реализовать с применением конкретных реализаций узлов, которые предусмотрено использовать при проектировании кластера.




Рис. 5. Результаты эксперимента по оценке влияния количества общих и активных контейнеров: а) на интенсивность обработки запросов контейнером; б) на загрузку процессора узла кластера

4. Приближенная модель оценки задержек обслуживания в компьютерной системе с контейнерной виртуализацией. При построении модели обслуживания рассматриваемых компьютерных систем предполагается, что узлы кластера функционируют в стационарном режиме. Поток запросов считается простейшим, а время обслуживания запросов – экспоненциальным. Обслуживание на разных узлах кластера (виртуальных машинах) предполагается независимым. Входной поток запросов с интенсивностью λ равномерно распределяется между контейнерами. Каждый контейнер моделируется как одноканальная система массового обслуживания с бесконечной очередью и простейшим входным потоком. Все контейнеры считаются однородными по функциональности и параметрам обслуживания. Предполагается, что запросы в очереди и во время обслуживания не теряются, а их репликация не осуществляется. Влияние отказов, сбоев и ошибок вычислений в данной модели не учитывается.

Для оценки задержек в узлах кластера (виртуальных машинах) предлагается использовать приближённые верхнюю, нижнюю и усреднённую оценки интенсивности обслуживания в каждом контейнере в зависимости от числа развернутых контейнеров и их активного числа, изменяющегося в процессе функционирования системы.

Построение приближённой модели проведём в соответствии со следующим алгоритмом:

1. Используя результаты эксперимента, представленного матрицей **M**, определим верхнее, нижнее и усреднённое значения интенсивности обслуживания запросов в контейнере.

2. По установленным (заданным) в пункте 1 значениям интенсивности обслуживания вычислим верхнюю, нижнюю и усреднённую оценки загрузки одного контейнера в зависимости от интенсивности входного потока запросов, равномерно распределяемого балансировщиком между узлами кластера и развернутыми в них контейнерами.

3. Определив загрузку контейнеров (вероятности их занятости), вычислим математическое ожидание числа активных контейнеров и вероятности различного числа активных контейнеров, обслуживающих функциональные запросы.

4. Оценим интенсивность обслуживания запросов в контейнерах, используя результаты расчётов вероятностей активности различного числа контейнеров m ($m = 1, 2, 3, \dots, n$), полученных на предыдущем этапе. Для этого умножим вычисленные вероятности на соответствующие значения интенсивности обслуживания $\mu(n, m)$, взятые из матрицы **M**, полученной экспериментально. Это позволит учесть влияние динамического разделения общедоступных ресурсов узла между активными и неактивными контейнерами.

5. Определив приближённое значение интенсивности обслуживания в контейнере с учётом влияния динамического разделения общедоступных ресурсов узла между активными и ожидающими запросов контейнерами, вычислим среднюю задержку запросов в очередях узлов кластера в зависимости от интенсивности поступающих в кластер запросов и числа контейнеров, развернутых в его узлах.

Аналогично (при повторении пунктов 1-4 алгоритма) может быть получена приближённая оценка вероятности своевременного обслуживания запросов в зависимости от интенсивности трафика и числа контейнеров, развернутых в узлах кластера. Оценка вероятности

своевременного обслуживания запросов проведена в разделе 5 данной статьи.

Рассмотрим построение модели обслуживания в системах с контейнерной виртуализацией более подробно.

Вначале рассмотрим обслуживание в узле кластера, укомплектованного одной виртуальной машиной с n развернутыми в ней контейнерами (рисунок 1).

При построении аналитической модели по п.1 приведённого алгоритма будем считать, что интенсивность обслуживания в контейнерах не зависит от изменений длины очереди (числа активных контейнеров). Загрузку контейнера при верхней, нижней и усреднённой оценке примем равной:

$$\rho = \frac{\lambda}{n \cdot \mu_g},$$

при этом μ_g – соответственно верхняя, нижняя либо усреднённая оценка интенсивности обслуживания запросов в контейнере, задаваемая в соответствии с пунктом 1 приведённого выше алгоритма.

Оценку интенсивности обслуживания μ_g можно получить с учётом результатов проведённых экспериментов. При этом возможны верхняя, нижняя и средняя оценки искомой загрузки контейнеров ρ .

При верхнем приближении загрузки контейнера ρ примем $\mu_g = \mu(n, n)$, при нижнем $\mu_g = \mu(n, 1)$, а при усреднённом $\mu_g = \sum_{i=1}^n \mu(n, i) / n$.

При этом значения $\mu(n, 1)$, $\mu(n, n)$ и $\mu(n, i)$ берутся с учётом экспериментально установленных результатов, представленных в матрице **М**. Погрешность усредненной оценки μ_g обусловлена тем, что все состояния с разным числом активных контейнеров считаются равно вероятными.

Таким образом, загрузка контейнера при верхней, нижней и усредненной оценке задается как:

$$\rho = \begin{cases} \lambda / n \mu(n, 1), & \text{при нижней оценке,} \\ \lambda / n \mu(n, n), & \text{при верхней оценке,} \\ \lambda / \sum_{i=1}^n \mu(n, i), & \text{при усредненной оценке.} \end{cases} \quad (1)$$

Упрощение модели обусловлено тем, что предполагается неизменность интенсивности обслуживания μ_g , а также загрузки контейнеров ρ , вне зависимости от текущей длины очереди.

В момент поступления запроса в некоторый контейнер среди остальных $n-1$ контейнеров могут быть заняты (активны) $i=0, 1, \dots, n-1$ контейнеров. Вероятность того, что в рассматриваемый момент времени поступления запроса активно i контейнеров, оценим как:

$$\rho_i = C_{n-1}^i \cdot \rho^i \cdot (1-\rho)^{n-i-1}, \quad (2)$$

где ρ оценивается по формуле (1).

Далее определим интенсивность обслуживания запросов в контейнерах с учетом вероятности активности различного числа контейнеров. При этом вероятность активности некоторого контейнера зададим через ранее определенное значение его загрузки ρ , которое вычисляется по формуле (2) при условии неизменности интенсивности обслуживания в контейнерах вне зависимости от их активного числа.

Интенсивность обслуживания в контейнере с учетом вероятности активности i контейнеров оценим следующим образом:

$$\mu = \sum_{i=0}^{n-1} \mu(n, i+1) \cdot C_{n-1}^i \cdot \rho^i (1-\rho)^{n-i-1}, \quad (3)$$

При этом $\mu(n, i+1)$ – интенсивность обслуживания запросов в контейнере при активности i контейнеров и развертывании n контейнеров на узле. Значение $\mu(n, i+1)$ определяется по матрице **M**, сформированной в результате описанного выше эксперимента.

Верхнюю, нижнюю и усредненную оценки математического ожидания интенсивности обслуживания в контейнере μ получаем соответственно при верхней μ_{upper} , нижней μ_{lower} и средней μ_{avg} оценках загрузки контейнеров ρ .

Результаты оценки интенсивности обслуживания в одном контейнере в зависимости от числа развернутых в виртуальной машине контейнеров для трех рассматриваемых приближений приведены на рисунке 6. Расчёт выполнен при интенсивности запросов $\lambda=19 \text{ c}^{-1}$.




Рис. 6. Оценка интенсивности обслуживания контейнером в зависимости от числа развернутых контейнеров n , результаты получены при верхней, нижней и средней оценке загрузки контейнеров

Рисунок 6 показывает, что интенсивность обслуживания в одном контейнере уменьшается с увеличением количества развернутых в узле контейнеров n .

Зависимость интенсивности обслуживания в контейнере от интенсивности запросов λ при $n=20$ (слева) и $n=10$ (справа) приведена на рисунке 7(а) и 7(б) соответственно.




Рис. 7. Оценка интенсивности обслуживания в контейнере в зависимости от интенсивности запросов λ при $n=20$ (а – слева) и $n=10$ (б – справа)

На рисунке 7 наблюдается, что интенсивность обслуживания в контейнере уменьшается при увеличении интенсивности запросов. Это объясняется тем, что с увеличением интенсивности запросов вероятность активации большего числа контейнеров также увеличивается, что приводит к уменьшению интенсивности обслуживания в каждом контейнере.

Верхнюю, нижнюю и среднюю оценки математического ожидания времени пребывания запросов T в узле кластера (в контейнере) вычислим как:

$$T_{lower} = \frac{1}{\frac{\mu_{upper}}{1 - \frac{\lambda}{n \cdot \mu_{upper}}}}, T_{upper} = \frac{1}{\frac{\mu_{lower}}{1 - \frac{\lambda}{n \cdot \mu_{lower}}}}, T_{avg} = \frac{1}{\frac{\mu_{avg}}{1 - \frac{\lambda}{n \cdot \mu_{avg}}}}. \quad (4)$$




Рис. 8. Оценка среднего времени пребывания запросов в контейнере T в зависимости от числа развернутых в узле контейнеров n

Оценка среднего времени пребывания запросов в контейнере T от числа развернутых в узле контейнеров по предлагаемой модели и при имитационном моделировании представлены на рисунке 8 при интенсивности запросов $\lambda = 19 \text{ c}^{-1}$. Имитационное моделирование [33] проведено с использованием языка Python и библиотеки моделирования SimPy [34 – 36], при этом контейнеры моделируются как объект службы с использованием класса SimPy.Resource.

Программа имитационного моделирования включает два ключевых этапа:

1. Преобразование потоков запросов, характеризующихся интервалами между ними, распределенными по экспоненциальному закону случайных величин, среднее значение которых задается пользователем.

2. Обслуживание запросов, когда время выполнения каждого запроса распределено экспоненциально.

На втором этапе учитывается зависимость интенсивности обслуживания в контейнере (*service_rate*) от общего числа контейнеров n и количества активных контейнеров m с использованием функции $\mu(n, m)$, отображаемой в матрице **M**. Эта взаимосвязь может быть учтена с помощью функции `SimPy.Resource.count`, которая предоставляет информацию о количестве занятых процессов в определенный момент времени, что является индикатором количества активных контейнеров.

Графики на рисунке 8 показывают, что верхняя, нижняя и усреднённая оценки не противоречат результатам имитационного моделирования. Средняя абсолютная процентная ошибка (MAPE) времени пребывания запросов в контейнере T_{avg} относительно результатов имитационного моделирования составляет 7,4%. Таким образом, можно считать, что предложенная аналитическая модель адекватно описывает поведение системы.

Из графика на рисунке 8 видно, что существует оптимальное число развернутых в узлах контейнеров n , при котором среднее время пребывания запросов T в системе минимально. При этом следует отметить, что искомое значение оптимального числа развернутых в узлах контейнеров n при верхней, нижней и усреднённой оценках времени пребывания запросов в системе практически совпадает.

Таким образом, из представленных зависимостей видно, что при проектировании систем контейнерной виртуализации предложенная аналитическая модель может использоваться для поиска оптимального числа реплик контейнеров (n), разворачиваемых в виртуальной машине.

На рисунке 9 отображено среднее время пребывания запросов в системе при различных значениях интенсивности запросов λ .

Расчет математического ожидания времени пребывания запросов в узле от интенсивности трафика при различных значениях количества развернутых контейнеров $n=5, 10, 15, 20$ отражен на рисунке 10.




Рис. 9. Время пребывания запросов в системе в зависимости от числа развернутых контейнеров n при значениях интенсивности запросов: а) $\lambda=5$; б) 10; в) 15; г) 20 c^{-1}




Рис. 10. Расчет математического ожидания времени пребывания запросов в узле от интенсивности трафика

Использование модели M/G/1. Установленная зависимость интенсивности обслуживания в контейнерах от числа n развернутых в

узле контейнеров и их активной части, зависящей от интенсивности входного потока, позволяет более точно представить процесс обслуживания в каждом контейнере моделью $M/G/1$.

В этом случае для определения среднего времени пребывания запроса в очереди контейнера воспользуемся формулой Полячека-Хинчина [16]:

$$w = \frac{\lambda_0 v^{(2)}}{2(1 - \rho_0)} = \frac{\lambda_0 v^{(2)}}{2(1 - \lambda_0 v)},$$

где $\lambda_0 = \lambda/n$, а v и $v^{(2)}$ первый и второй начальный момент времени обслуживания запросов в контейнере при заданном числе развернутых контейнеров n . Искомые первый и второй начальные моменты найдем на основе перебора гипотез с определением вероятности активности различного числа из развернутых контейнеров:

$$v = \sum_{i=0}^{n-1} \left(\frac{1}{\mu(n, i+1)} \right) \cdot C_{n-1}^i \cdot \left(\frac{\lambda}{n\mu_s} \right)^i \left(1 - \frac{\lambda}{n\mu_s} \right)^{n-i-1},$$

$$v^{(2)} = \sum_{i=0}^{n-1} \left(\frac{1}{\mu(n, i+1)} \right)^2 \cdot C_{n-1}^i \cdot \left(\frac{\lambda}{n\mu_s} \right)^i \left(1 - \frac{\lambda}{n\mu_s} \right)^{n-i-1},$$

при этом $\frac{\lambda}{n\mu_s} < 1$ вероятность, что некоторой контейнер активен,

а уточнение оценки интенсивности обслуживания в контейнере

$$\mu_s = \sum_{i=0}^{n-1} \mu(n, i+1) \cdot C_{n-1}^i \cdot \left(\frac{\lambda}{n\mu} \right)^i \left(1 - \frac{\lambda}{n\mu} \right)^{n-i-1},$$

где μ определялся по формуле (3).

Учет задержки распределения запросов. Для кластеров, объединяющих N виртуальных машин, в каждой из которых развернуто n контейнеров, при вычислении среднего времени пребывания запросов в системе помимо рассмотренной выше оценки задержек в узле кластера необходимо учитывать дополнительную

задержку распределения запросов T_p по узлам кластера при балансировке нагрузки.

При распределении запросов с балансировкой нагрузки интенсивность запросов, поступающих в кластер $\lambda_{\text{вх}}$, равномерно распределяется по его узлам, то есть интенсивность поступления запросов в узел кластера будет равна $\lambda = \lambda_{\text{вх}}/N$. Если при балансировке загрузки в кластере очереди не формируется (рисунок 2), то время распределения запросов $T_p = \nu_p$, где ν_p – средние задержки в балансировщике при распределении запросов. Если в кластере очередь на диспетчеризацию (распределение с балансировкой) образуется (рис.3), то при представлении диспетчера (балансировщика) в виде классической одноканальной системы с бесконечной очередью типа М/М/1, имеем задержки распределения запросов:

$$T_p = \frac{\nu_p}{(1 - \lambda_{\text{вход}} \cdot \nu_p)}.$$

Представленная приближённая модель позволяет установить аналитическую зависимость задержек ожидания запросов в очередях для кластерных систем с контейнерной виртуализацией.

Развитие предложенных моделей может включать исследование влияния на задержки обслуживания и нарушения непрерывности функционирования из-за отказов, приводящих к потере времени на реконфигурацию структуры и контроль функционирования. Уточнение моделей может проводиться с учетом возможной неопределенности трафика и его периодических изменений. Представляется целесообразным исследование потенциальных возможностей уточнения предлагаемых моделей на основе композиционного подхода к имитационному моделированию систем массового обслуживания с параметрической неопределенностью [33].

5. Оценка вероятности своевременного обслуживания запросов. Предлагаемые выше приближенные модели массового обслуживания кластеров с контейнерной виртуализацией позволяют оценить среднее время пребывания запросов с учетом влияния на интенсивность их обслуживания числа развернутых и активных контейнеров, совместно использующих общие вычислительные ресурсы узлов.

Для функционирования кластера при ограничении на допустимое время ожидания важна оценка вероятности обслуживания запросов за время, меньшее предельно допустимого t_0 .


Функционирование контейнера представим моделью массового обслуживания с неограниченной очередью типа М/М/1. По результатам оценки математического ожидания интенсивности μ , с учетом влияния общего числа развернутых и активных контейнеров (пункты 1-4 приведенного выше алгоритма построения приближенной модели обслуживания), вероятность не превышения при ожидании в контейнере предельно допустимого времени t_0 определим как:

$$P = 1 - \frac{\lambda}{n\mu} e^{\left(\frac{\lambda}{n} - \mu\right)t_0}. \quad (5)$$


При расчетах может быть взято верхнее нижнее или усредненное значение интенсивности обслуживания запросов, полученное выше по формуле (3).

Искомая зависимость вероятности своевременного обслуживания запросов в узле кластера P за время, меньшее t_0 , от интенсивности поступления запросов в узел кластера λ приведена на рисунке 11(а) для верхнего (P_{max}), нижнего (P_{min}) и усреднённого (P_{avg}) приближений. Из рисунка 11(а) видно, что разброс между верхней и нижней оценками увеличивается по мере роста интенсивности запросов λ (1/с) и числа развернутых в узле контейнеров. Расчёт проведён при предельно допустимом времени ожидания $t_0=0,3$ с. На рисунке 11(б) отражена зависимость усреднённой оценки вероятности своевременного обслуживания P от интенсивности запросов λ (1/с) при развертывании в виртуальной машине $n=3$, $n=5$ и $n=10$ контейнеров при допустимом времени ожидания $t_0=0,3$ с и $t_0=0,4$ с. Из рисунка 11(б) видно, что увеличение числа развертываемых в узле контейнеров не всегда однозначно приводит к повышению вероятности обслуживания P за время, не превосходящее предельно допустимое t_0 время ожидания.

Результаты граничных (верхней и нижней) и усредненной оценок вероятности выполнения запросов P за время меньшее t_0 при изменениях числа контейнеров в узле n представлены на рисунке 12.



a)



б)

Рис. 11. Результаты граничных (верхней и нижней) и усредненной оценок вероятности выполнения запросов P за время меньше t_0 при изменениях интенсивности λ (1/с) трафика




Рис. 12. Результаты граничных (верхней и нижней) и усредненной оценок вероятности выполнения запросов P за время меньше t_0 при изменениях числа контейнеров в узле n

Представленные на рисунке 12 графики показывают существование оптимального числа развернутых в узлах кластера контейнеров, при котором достигается максимум вероятности своевременного обслуживания запросов.

Проведенные исследования показывают, что при использовании верхней, нижней и усредненной оценки интенсивности обслуживания в контейнерах искомое оптимальное значение числа развертываемых в узле контейнеров имеет близкие целочисленные значения.

В данной статье (рисунок 8) показано существование оптимального числа развернутых контейнеров в узле, при котором обеспечивается минимум времени пребывания запросов в узле. Постановка и решение задачи оптимизации выходит за рамки данного исследования и требует дополнительных исследований, в том числе при возможности изменений интенсивности входного потока (например, его периодических изменений в течение суток). В простейшем случае, когда интенсивность входного потока задана, возможна следующая простейшая постановка оптимизации.

Для систем, к которым не предъявляется требование выполнения запросов за предельно допустимое время, в качестве

критерия оптимальности (целевой функции) используется минимум среднего времени пребывания запросов в системе.

Для систем, к которым предъявляется требование выполнения запросов за предельно допустимое время, в качестве критерия оптимальности используется максимум вероятности не превышения задержек ожидания предельно допустимого времени t_0 , определяемой по формуле (5).

Для каждого из сформулированных критерием в качестве параметра управления выступает число контейнеров n разворачиваемых в узле. В качестве ограничений рассматривается условие стационарности $\frac{\lambda}{n \cdot \mu} < 1$, где μ определяется по формуле (3).

В качестве ограничения также может вводиться наибольшее число разворачиваемых в узле контейнеров.

Предложенные приближенные модели массового обслуживания в кластерных системах с компьютерной виртуализацией позволяют установить влияния числа разворачиваемых в узлах кластера контейнеров на задержку и вероятность своевременного обслуживания запросов.

Обсуждение результатов и направления развития. Новизна предлагаемой модели массового обслуживания кластера с контейнерной виртуализацией заключается в учете влияния разделения общих ресурсов между активными и неактивными контейнерами на снижение интенсивности обслуживания в каждом контейнере.

Отличие предлагаемой модели кластера с контейнерной виртуализацией состоит в представлении кластера группой одноканальных взаимозависимых СМО, каждая из которых соответствует отдельному контейнеру. Взаимозависимость одноканальных СМО, объединяемых в группу, обусловлена тем, что распределение общих ограниченных ресурсов между активными и неактивными контейнерами, приводит к снижению интенсивности обслуживания в каждом из них. Особенность предлагаемой модели заключается в учете этой взаимозависимости отдельных одноканальных СМО.

Развитие предлагаемых моделей для структурно-параметрической оптимизации кластерных систем с контейнерной виртуализацией предусматривается в направлении учета влияния отказов, сбоев и ошибок вычислений [37 – 40]. Модели должны быть ориентированы на оптимизацию кластера в условиях многокритериальности и стохастической неопределенности трафика,

в том числе при его функциональной и параметрической неоднородности, включая неоднородность запросов по критичности к допустимому времени их ожидания [13, 14, 41, 42]. Для распределенных компьютерных систем, предусматривающих межмашинный обмен данными через сеть [13, 14, 43], при оценке надежности и задержек передач необходим учет избыточности их топологии и возможности организации многопутевых передач, в том числе с репликацией и сегментацией передаваемых данных [13, 14, 44].

В дальнейшем предполагается построение модели надежности рассматриваемых систем и постановку задачи многокритериальной оптимизации. В качестве критерия, объединяющего рассмотренные в данной статье показатели задержек и показатели надежности, предполагается использовать, в частности, коэффициент готовности к выполнению запросов в установленные сроки [45]. Заметим, что этот критерий не формальный, а имеет физический смысл.

В направлении исследование возможностей изоляции различных вычислений, выполняемых одновременно, в рамках одного вычислительного устройства известных из [15] предполагается построение моделей, не ограниченных простейшими потоками и экспоненциальным обслуживанием [46], с учетом особенностей контейнерной виртуализации. Указанные направления развития работы ориентированы на возможность количественного обоснования выбора решений по контейнерной виртуализации, а также сравнения и обоснования выбора с учетом других технологий виртуализации [47 – 52].

6. Заключение. Предложена приближенная аналитическая оценка вероятностно временных показателей качества обслуживания запросов в кластерных системах конвейерной виртуализации, получаемая при сочетании экспериментальных исследований и аналитического моделирования.

При построении аналитической модели обслуживания каждый контейнер представляется как отдельная одноканальная система массового обслуживания с бесконечной очередью и простейшим входным потоком. Основное отличие предлагаемой модели виртуального кластера заключается в граничной верхней, нижней и усредненной оценке возможного снижения интенсивности обслуживания в контейнерах из-за разделения между ними ограниченных общедоступных вычислительных ресурсов узла кластера в зависимости от количества развернутых в нем контейнеров

и изменяющегося числа активных контейнеров, зависящем от интенсивности входного потока.

На основе предлагаемых приближенных граничных моделей оценки среднего времени пребывания запросов в кластере и вероятности их своевременного обслуживания за время, не превышающее предельно допустимое значение, проведено исследование возможностей повышения эффективности кластерных систем конвейерной виртуализации. Оценка вероятности обслуживания запросов за время не превышающее предельно допустимое время особенно важно для систем, критичных к своевременности и непрерывности реализации вычислительного процесса.

Показано существование оптимального числа развернутых в узлах контейнеров, при котором среднее время пребывания запросов в системе минимально либо вероятность выполнения запросов за время меньшее предельно допустимого максимальна. При этом следует отметить, что целочисленные значения оптимального числа развернутых в узлах контейнеров, искомые при верхней, нижней и усредненной оценке, имеют достаточно близкие значения.

Предлагаемые модели могут быть применены при структурно-параметрической оптимизации кластеров с конвейерной виртуализацией, в том числе в случае масштабирования и адаптивной реконфигурации к изменениям трафика в системе. Реконфигурация кластера при изменениях трафика реализуется в результате перенастройки числа развернутых контейнеров.

Литература

1. Kumari P., Kaur P. A survey of fault tolerance in cloud computing // Journal of King Saud University-Computer and Information Sciences. 2021. vol. 33(10). pp. 1159-1176. DOI: 10.1016/j.jksuci.2018.09.021.
2. Половко А.М., Гуров С.В. Основы теории надежности // СПб.: БХВ-Петербург, 2006. 702 с.
3. Goyal P., Deora S.S. Reliability of Trust Management Systems in Cloud Computing // Indian Journal of Cryptography and Network Security (IJCNS). 2022. vol. 2. no. 1. pp. 1-5. DOI: 10.54105/ijcns.C1417.051322.
4. Chen G., Guan N., Huang K., Yi W. Fault-tolerant real-time tasks scheduling with dynamic fault handling // Journal of Systems Architecture. 2020. vol. 102. DOI: 10.1016/j.sysarc.2019.101688.
5. Shubinsky I.B., Rozenberg I.N., Papic L. Adaptive fault tolerance in real-time information systems // Reliability: Theory & Applications. 2017. vol. 12. no 1(44). pp. 18–25.
6. Alam K., Sharif K., Li F., Latif Z., Karim M.M., Biswas S., Nour B., Wang Y. A Survey of Network Virtualization Techniques for Internet of Things Using SDN and NFV // ACM Computing Surveys (CSUR). 2020. vol. 53. no. 2. pp. 1–40. DOI: 10.1145/3379444.

7. Shukur H., Zeebaree S., Zebari R., Zeebaree D., Ahmed O. Cloud computing virtualization of resources allocation for distributed systems // *Journal of Applied Science and Technology Trends*. 2020. vol. 1. no. 2. pp. 98–105. DOI: 10.38094/jastt1331.
8. Compastié M., Badonnel R., Festor O., He R. From virtualization security issues to cloud protection opportunities: An in-depth analysis of system virtualization models // *Computers & Security*. 2020. vol. 97. DOI: 10.1016/j.cose.2020.101905.
9. Li Z., Jin H., Zou D., Yuan B. Exploring New Opportunities to Defeat Low-Rate DDos Attack in Container-Based Cloud Environment // *IEEE Transactions on Parallel and Distributed Systems*. 2020. vol. 31. no. 3. pp. 695–706. DOI: 10.1109/TPDS.2019.2942591.
10. Chen H., Qin W., Wang L. Task partitioning and offloading in IoT cloud-edge collaborative computing framework: a survey // *Journal of Cloud Computing*. 2022. vol. 11. no. 1. DOI: 10.1186/s13677-022-00365-8.
11. Kushchazli A., Safargalieva A., Kochetkova I., Gorshenin A. Queuing Model with Customer Class Movement across Server Groups for Analyzing Virtual Machine Migration in Cloud Computing // *Mathematics*. 2024. vol. 12. no. 3. DOI: 10.3390/math12030468.
12. Choudhary A., Govil M.C., Singh G., Awasthi L.K., Pilli E.S., Kapil D. A critical survey of live virtual machine migration techniques // *Journal of Cloud Computing*. 2017. vol. 6. DOI: 10.1186/s13677-017-0092-1.
13. Bogatyrev V.A., Bogatyrev A.V., Bogatyrev S.V. The probability of timeliness of a fully connected exchange in a redundant real-time communication system // *Wave Electronics and its Application in Information and Telecommunication Systems (WECONF 2020)*. 2020. pp. 1–4. DOI: 10.1109/WECONF48837.2020.9131517.
14. Bogatyrev V.A., Bogatyrev A.V., Bogatyrev S.V. Multipath Transmission of Heterogeneous Traffic in Acceptable Delays with Packet Replication and Destruction of Expired Replicas in the Nodes that Make Up the Path // *Communications in Computer and Information Science*. 2023. vol. 1748. pp. 104–121.
15. Клейнрок Л. Вычислительные системы с очередями / перевод с английского под редакцией д-ра техн. наук Б.С. Цыбакова. Москва: Мир, 1979. 600 с.
16. Клейнрок Л. Теория массового обслуживания // М.: Машиностроение, 1979. 432 с.
17. Ejem A., Njoku C.N., Uzoh O.F., Odii J.N. Queue Control Model in a Clustered Computer Network using M/M/m Approach // *International Journal of Computer Trends and Technology (IJCTT)*. 2016. vol. 35. no. 1. pp. 12–20. DOI: 10.14445/22312803/IJCTT-V35P103.
18. Khalil M.M., Khomonenko A.D., Gindin S.I. Load balancing cloud computing with web-interface using multi-channel queuing systems with warming up and cooling // *Intelligent Distributed Computing XIII*. 2020. vol. 868. pp. 385–393. DOI: 10.1007/978-3-030-32258-8_45.
19. Mochalov V.P., Bratchenko N.Yu., Linets G.I., Palkanov I.S. Methods and models of resource allocation in load balancing clusters s for data centers // *Modeling, Optimization and Information Technology*. 2022. vol. 10. no. 2. pp. 1–15. DOI: 10.26102/2310-6018/2022.37.2.030.
20. Volkov A.O. Evaluation of cloud computing cluster performance // *T-Comm*. 2020. vol. 14. no. 12. pp. 72–79. DOI: 10.13140/RG.2.2.32529.86885.
21. Goncharenko V.A., Lokhvitsky V.A. Cluster Load Balancing Algorithms Based on Shortest Queue Models // *Intellectual Technologies on Transport*. 2022. vol. 3. no. 31. pp. 37–45. DOI: 10.24412/2413-2527-2022-331-37-45.

22. Мартыначук И.Г. Прогнозирование мультисезонных нагрузочных процессов в эластичных системах // Изв. вузов. Приборостроени. 2023. Т. 66. № 11. С. 907–916. DOI: 10.17586/0021-3454-2023-66-11-907-916.
23. Singh P. Mathematical Rendition of Generic Process Model-based Design for Decision Making about Cloud Instance Autoscaling Actions // IOSR Journal of Mathematics (IOSR-JM). 2021. vol. 17. no. 3. pp. 49–56. DOI: 10.9790/5728-1703024956.
24. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Recovery of Real-Time Clusters with the Division of Computing Resources into the Execution of Functional Queries and the Restoration of Data Generated Since the Last Backup // International Conference on Distributed Computer and Communication Networks. 2023. pp. 236–250. DOI: 10.1007/978-3-031-50482-2_19.
25. Богатырев В.А., Богатырев С.В., Богатырев А.В. Оценка готовности компьютерной системы к своевременному обслуживанию запросов при его совмещении с информационным восстановлением памяти после отказов // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 3. С. 608–617. DOI: 10.17586/2226-1494-2023-23-3-608-617.
26. Srivastava A., Kumar N. Queueing model based dynamic scalability for containerized cloud // International Journal of Advanced Computer Science and Applications. 2023. vol. 14. no. 1. pp. 465–472. DOI: 10.14569/IJACSA.2023.0140150.
27. Khazaei H., Barna C., Beigi-Mohammadi N., Litoiu M. Efficiency analysis of provisioning microservices // Proceedings of the International Conference on Cloud Computing Technology and Science (CloudCom). IEEE. 2016. pp. 261–268.
28. Liu B., Chen Y. A scalable fine-grained analytic model for container cloud data centres // Int. J. Internet Technol. Secur. Trans. 2019. vol. 9. no. 4. pp. 355–389.
29. Ye T., Guangtao X., Shiyong Q., Minglu L. An auto-scaling framework for containerized elastic applications // Proceedings of the 3rd International Conference on Big Data Computing and Communications (BIGCOM), IEEE. 2017. pp. 422–430.
30. El Kafhali S., El Mir I., Salah K., Hanini M. Dynamic Scalability Model for Containerized Cloud Services // Arabian Journal for Science and Engineering. 2020. vol. 45(12). pp. 10693–10708. DOI: 10.1007/s13369-020-04847-2.
31. Фунг В., Богатырев В.А., Кармановский Н.С., Лэ В. Оценка вероятностно-временных характеристик компьютерной системы с контейнерной виртуализацией // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24. № 2. С. 249–255.
32. Фунг В., Богатырев В.А. Задержки и надежность обслуживания запросов в виртуальном компьютерном кластере // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2024. № 68. С. 48–58.
33. Гончаренко В.А., Хомоненко А.Д., Абу Хасан Р. Композиционный подход к имитационному моделированию систем массового обслуживания со случайными параметрами // Информатика и автоматизация. 2024. Т. 23. № 6. С. 1577–1608. DOI: 10.15622/ia.23.6.1
34. Syed Z.A., Gummadi S., Mahima E.L., Naina S.R., Eswaran S., Honnavalli P. Performance Analysis Of 5G Network Slicing Simulations Using SimPy // Proceedings of the 2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT). Bangalore, India: IEEE. 2022. pp. 1–6. DOI: 10.1109/CONECCT55679.2022.9865799.
35. Peyman M., Copado P., Panadero J., Juan A.A., Dehghanimohammadabadi M. A Tutorial on how to Connect Python with Different Simulation Software to Develop Rich Simheuristics // Proceedings of the 2021 Winter Simulation Conference (WSC). Phoenix, AZ, USA: IEEE, 2021. pp. 1–12. DOI: 10.1109/WSC52266.2021.9715511.

36. Nam S.H., Oh S.H., Yoon H.C., Cho Y.I., Cho K.Y., Kwak D.H., Woo J.H. Development of DES Application for Factory Material Flow Simulation with SimPy // Proceedings of the 2022 Winter Simulation Conference (WSC), Singapore. IEEE. 2022. pp. 1545–1556. DOI: 10.1109/WSC57314.2022.10015508.
37. Oszczypała M., Ziółkowski J., Małachowski J. Redundancy allocation problem in repairable k-out-of-n systems with cold, warm, and hot standby: A genetic algorithm for availability optimization // Applied Soft Computing. 2024. vol. 165. DOI: 10.1016/j.asoc.2024.112041.
38. Oszczypała M., Konwerski J., Ziółkowski J., Małachowski J. Reliability analysis and redundancy optimization of k-out-of-n systems with random variable k using continuous time Markov chain and Monte Carlo simulation // Reliability Engineering & System Safety. 2024. vol. 242. DOI: 10.1016/j.res.2023.109780.
39. Komari I.E., Fedorenko M., Kharchenko V., Yehorova Y., Bardis N., Lutai L. The neural modules network with collective relearning for the recognition of diseases: Fault-tolerant structures and reliability assessment // Neural Networks. 2020. vol. 1. DOI: 10.46300/9106.2020.14.102.
40. Kumar A., Saini M., Saini D.K., Badiwal, N. Cyber physical systems-reliability modelling: critical perspective and its impact // International Journal of System Assurance Engineering and Management. 2021. vol. 12. pp. 1334–1347. DOI: 10.1007/s13198-021-01305-6.
41. Lambropoulos G., Mitropoulos S., Douligeris C. Improving Business Performance by Employing Virtualization Technology: A Case Study in the Financial Sector // Computers. 2021. vol. 10. no. 4. DOI: 10.3390/computers10040052.
42. Shi F., Lin J. Virtual machine resource allocation optimization in cloud computing based on multiobjective genetic algorithm // Computational Intelligence and Neuroscience. 2022. vol. 2022. no. 1. DOI: 10.1155/2022/7873131.
43. Al-Dulaimi M.K.H., Al-Dulaimi O.M.K., Al-Dulaimi A.M.K., Alexandra M.O., Jihad N. Deep Learning for Wireless Network Distribution (5G/LTE) // Proceedings of the 2023 4th International Conference on Communications, Information, Electronic and Energy Systems (CIEES). Plovdiv, Bulgaria: IEEE, 2023. pp. 1–6. DOI: 10.1109/CIEES58940.2023.10378816.
44. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Control of Multipath Transmissions in the Nodes of Switching Segments of Reserved Paths // International Conference on Information, Control, and Communication Technologies (ICCT). IEEE, 2022. pp. 1–5.
45. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Reliability and Timeliness of Servicing Requests in Infocommunication Systems, Taking into Account the Physical and Information Recovery of Redundant Storage Devices // International Conference on Information, Control, and Communication Technologies (ICCT). IEEE, 2022. pp. 1–4.
46. Хомоненко А.Д., Благовещенская Е.А., Проурзин О.В., Андрук А.А. Прогноз надежности кластерной вычислительной системы с помощью полумарковской модели альтернирующих процессов и мониторинга // Наукоемкие технологии в космических исследованиях Земли. 2018. Т. 10. № 4. С. 72–82. DOI: 10.24411/2409-5419-2018-10099.
47. Sturley H., Fourmier A., Salcedo-Navarro A., Garcia-Pineda M., Segura-Garcia J. Virtualization vs. containerization, a comparative approach for application deployment in the continuum focused on the edge // Future Internet. 2024. vol. 16. no. 11.
48. Aniruddh M., Dinkar A., Mouli S.C., Sahana B., Deshpande A.A. Comparison of containerization and virtualization in cloud architectures // 2021 IEEE International conference on electronics, computing and communication technologies (CONECT). 2021. pp. 1–5.

49. Abuabdo A., Al-Sharif Z.A. Virtualization vs. containerization: towards a multithreaded performance evaluation approach // 2019 IEEE/ACS 16th international conference on computer systems and applications (AICCSA). 2019. pp. 1–6.
50. Kumar S. A brief study on virtualization and containerization // Cloud computing. 2022. pp. 37–46.
51. Xu J., Fortes J.A. Multi-objective virtual machine placement in virtualized data center environments // 2010 IEEE/ACM International conference on green computing and communications (GreenCom) and International conference on cyber, physical and social computing (CPSCom). 2010. pp. 179–188.
52. Ходосов М.А. Анализ технологий виртуализации // ИИАСУ'23 – Искусственный интеллект в автоматизированных системах управления и обработки данных: Сборник статей II Всероссийской научной конференции (Москва, 27–28 апреля 2023 г.): в 5 т. М.: «КДУ», «Добросвет», 2024. Т. 4. С. 475–481. DOI: 10.31453/kdu.ru.978-5-7913-1354-6-2024-488.

Богатырев Владимир Анатольевич — д-р техн. наук, профессор факультета, факультет программной инженерии и компьютерной техники, Университет ИТМО; профессор кафедры, кафедра информационной безопасности, Санкт-Петербургский государственный университет аэрокосмического приборостроения (ГУАП). Область научных интересов: теория и методы обеспечения надежности, отказоустойчивости и эффективности компьютерных систем и сетей. Число научных публикаций — 460. vladimir.bogatyrev@gmail.com; Кронверкский проспект, 49А, 197101, Санкт-Петербург, Россия; р.т.: +7(812)232-5278.

Фунг Ван Кю — аспирант, факультет программной инженерии и компьютерной техники, Университет ИТМО. Область научных интересов: система интернета вещей, теория надежности, теория массового обслуживания, отказоустойчивости и эффективности компьютерных систем и сетей. Число научных публикаций — 5. phungvanquy97@gmail.com; Кронверкский проспект, 49А, 197101, Санкт-Петербург, Россия; р.т.: +7(995)990-8193.

V. BOGATYREV, V. PHUNG
**AN APPROXIMATE ASSESSMENT OF LATENCY IN A
COMPUTER SYSTEM WITH CONTAINER VIRTUALIZATION**

Bogatyrev V., Phung V. An Approximate Assessment of Latency in a Computer System with Container Virtualization.

Abstract. The key role in achieving high reliability, security, fault tolerance, and low latency of query service in distributed systems (including cloud computing) is played by the consolidation of data processing and storage resources in clusters, the efficiency of which increases with the use of virtual machine technologies and container virtualization. The complexity of building queuing models for container virtualization systems is caused by the fact that the intensity of query execution in each container is associated with the dynamic division of shared resources between active (performing functional tasks) containers and the costs of supporting all containers deployed in the VM, including inactive containers waiting for service requests to be sent to them. The reduction in service intensity in each container due to shared resource allocation depends on many factors that are difficult to investigate. For clusters with container virtualization, this article provides an approximate boundary estimate of the average request waiting time and the probability of timely service. When building an analytical model, each container is represented as a separate single-channel queuing system with an infinite queue and the simplest input stream. The key feature of the proposed virtual cluster model is the estimation of upper, lower, and average bounds for the potential service intensity reduction in containers, resulting from the allocation of a node's limited computing resources among them. This depends on the number of deployed containers and the dynamically varying count of active containers, which is influenced by the input stream intensity. The study demonstrates the existence of an optimal number of containers per node, minimizing the average request processing time or maximizing the probability of timely request execution. The proposed models can be applied to the structural and parametric optimization of clusters with pipelined virtualization, including in the case of scaling and reconfiguration adaptive to traffic changes by disconnecting or connecting some of the deployed containers depending on changes in the load in the system.

Keywords: container, container virtualization, cluster, resource allocation, latency.

References

1. Kumari P. Kaur P. A survey of fault tolerance in cloud computing. Journal of King Saud University-Computer and Information Sciences. 2021. vol. 33(10). pp. 1159-1176. DOI: 10.1016/j.jksuci.2018.09.021.
2. Polovko A.M., Gurov S.V. Osnovy teorii nadezhnosti [Fundamentals of Reliability Theory]. SPb.: BHV-Peterburg. 2006. 702 p. (In Russ.).
3. Goyal P., Deora S.S. Reliability of Trust Management Systems in Cloud Computing. Indian Journal of Cryptography and Network Security (IJCNS). 2022. vol. 2. no. 1. pp. 1-5. DOI: 10.54105/ijcns.C1417.051322.
4. Chen G., Guan N., Huang K., Yi W. Fault-tolerant real-time tasks scheduling with dynamic fault handling. Journal of Systems Architecture. 2020. vol. 102. DOI: 10.1016/j.sysarc.2019.101688.
5. Shubinsky I.B., Rozenberg I.N., Papic L. Adaptive fault tolerance in real-time information systems. Reliability: Theory & Applications. 2017. vol. 12. no 1(44). pp. 18–25.

6. Alam K., Sharif K., Li F., Latif Z., Karim M.M., Biswas S., Nour B., Wang Y. A Survey of Network Virtualization Techniques for Internet of Things Using SDN and NFV. *ACM Computing Surveys (CSUR)*. 2020. vol. 53. no. 2. pp. 1–40. DOI: 10.1145/3379444.
7. Shukur H., Zeebaree S., Zebari R., Zeebaree D., Ahmed O. Cloud computing virtualization of resources allocation for distributed systems. *Journal of Applied Science and Technology Trends*. 2020. vol. 1. no. 2. pp. 98–105. DOI: 10.38094/jastt1331.
8. Compastié M., Badonnel R., Festor O., He R. From virtualization security issues to cloud protection opportunities: An in-depth analysis of system virtualization models. *Computers & Security*. 2020. vol. 97. DOI: 10.1016/j.cose.2020.101905.
9. Li Z., Jin H., Zou D., Yuan B. Exploring New Opportunities to Defeat Low-Rate DDoS Attack in Container-Based Cloud Environment. *IEEE Transactions on Parallel and Distributed Systems*. 2020. vol. 31. no. 3. pp. 695–706. DOI: 10.1109/TPDS.2019.2942591.
10. Chen H., Qin W., Wang L. Task partitioning and offloading in IoT cloud-edge collaborative computing framework: a survey. *Journal of Cloud Computing*. 2022. vol. 11. no. 1. DOI: 10.1186/s13677-022-00365-8.
11. Kushchazli A., Safargalieva A., Kochetkova I., Gorshenin A. Queuing Model with Customer Class Movement across Server Groups for Analyzing Virtual Machine Migration in Cloud Computing. *Mathematics*. 2024. vol. 12. no. 3. DOI: 10.3390/math12030468.
12. Choudhary A., Govil M.C., Singh G., Awasthi L.K., Pilli E.S., Kapil D. A critical survey of live virtual machine migration techniques. *Journal of Cloud Computing*. 2017. vol. 6. DOI: 10.1186/s13677-017-0092-1.
13. Bogatyrev V.A., Bogatyrev A.V., Bogatyrev S.V. The probability of timeliness of a fully connected exchange in a redundant real-time communication system. *Wave Electronics and its Application in Information and Telecommunication Systems (WECONF 2020)*. 2020. pp. 1–4, DOI: 10.1109/WECONF48837.2020.9131517.
14. Bogatyrev V.A., Bogatyrev A.V., Bogatyrev S.V. Multipath Transmission of Heterogeneous Traffic in Acceptable Delays with Packet Replication and Destruction of Expired Replicas in the Nodes that Make Up the Path. *Communications in Computer and Information Science*. 2023. vol. 1748. pp. 104–121.
15. Kleinrock, L. *Vychislitel'nye sistemy s ocheredjami* [Computing systems with queues]. Moscow : Mir Publ., 1979. 600 p. (In Russ.).
16. Klejnrok L. *Teorija massovogo obsluzhivaniya* [Theory of Queueing Systems]. M.: Mashinostroenie. 1979. 432 p. (In Russ.).
17. Ejem A., Njoku C.N., Uzoh O.F., Odii J.N. Queue Control Model in a Clustered Computer Network using M/M/m Approach. *International Journal of Computer Trends and Technology (IJCTT)*. 2016. vol. 35. no. 1. pp. 12–20. DOI: 10.14445/22312803/IJCTT-V35P103.
18. Khalill M.M., Khomonenko A.D., Gindin S.I. Load balancing cloud computing with web-interface using multi-channel queuing systems with warming up and cooling. *Intelligent Distributed Computing XIII*. 2020. vol. 868. pp. 385–393. DOI: 10.1007/978-3-030-32258-8_45.
19. Mochalov V.P., Bratchenko N.Yu., Linets G.I., Palkanov I.S. Methods and models of resource allocation in load balancing clusters s for data centers. *Modeling, Optimization and Information Technology*. 2022. vol. 10. no. 2. pp. 1–15. DOI: 10.26102/2310-6018/2022.37.2.030.
20. Volkov A.O. Evaluation of cloud computing cluster performance. *T-Comm*. 2020. vol. 14. no. 12. pp. 72–79. DOI: 10.13140/RG.2.2.32529.86885.

21. Goncharenko V.A., Lokhvitsky V.A. Cluster Load Balancing Algorithms Based on Shortest Queue Models. *Intellectual Technologies on Transport*. 2022. vol. 3. no. 31. pp. 37–45. DOI: 10.24412/2413-2527-2022-331-37-45.
22. Martynchuk I.G. [Forecasting multi-seasonal load processes in elastic computing systems]. *Journal of Instrument Engineering*. 2023. vol. 66. no. 11. pp. 907–916. DOI: 10.17586/0021-3454-2023-66-11-907-916. (In Russ.).
23. Singh P. Mathematical Rendition of Generic Process Model-based Design for Decision Making about Cloud Instance Autoscaling Actions. *IOSR Journal of Mathematics (IOSR-JM)*. 2021. vol. 17. no. 3. pp. 49–56. DOI: 10.9790/5728-1703024956.
24. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Recovery of Real-Time Clusters with the Division of Computing Resources into the Execution of Functional Queries and the Restoration of Data Generated Since the Last Backup. *International Conference on Distributed Computer and Communication Networks*. 2023. pp. 236–250. DOI: 10.1007/978-3-031-50482-2_19.
25. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. [Assessment of the readiness of a computer system for timely servicing of requests when combined with information recovery after failures] *Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki – Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*. 2023. vol. 23. no. 3. pp. 608–617. DOI: 10.17586/2226-1494-2023-23-3-608-617. (In Russ.).
26. Srivastava A., Kumar N. Queueing model based dynamic scalability for containerized cloud. *International Journal of Advanced Computer Science and Applications*. 2023. vol. 14. no. 1. pp. 465–472. DOI: 10.14569/IJACSA.2023.0140150.
27. Khazaei H., Barna C., Beigi-Mohammadi N., Litoiu M. Efficiency analysis of provisioning microservices. *Proceedings of the International Conference on Cloud Computing Technology and Science (CloudCom)*. IEEE. 2016. pp. 261–268.
28. Liu B., Chen Y. A scalable fine-grained analytic model for container cloud data centres. *Int. J. Internet Technol. Secur. Trans.* 2019. vol. 9. no. 4. pp. 355–389.
29. Ye T., Guangtao X., Shiyu Q., Minglu L. An auto-scaling framework for containerized elastic applications. *Proceedings of the 3rd International Conference on Big Data Computing and Communications (BIGCOM)*, IEEE. 2017. pp. 422–430.
30. El Kafhali S., El Mir I., Salah K., Hanini M.. Dynamic Scalability Model for Containerized Cloud Services. *Arabian Journal for Science and Engineering*. 2020. vol. 45(12). pp. 10693–10708. DOI: 10.1007/s13369-020-04847-2.
31. [Assessment of probabilistic-temporal characteristics of a computer system with container virtualization]. *Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki – Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*. 2024. vol. 24. no. 2. pp. 249–255. (In Russ.).
32. Phung V., Bogatyrev V.A. [Delays and Reliability of Query Processing in a Virtual Computer Cluster]. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naja tehnika i informatika – Bulletin of Tomsk State University. Management, computer engineering and computer science*. 2024. no. 68. pp. 48–58. (In Russ.).
33. Goncharenko V., Khomonenko A., Abu Khasan R. [A Compositional Approach to the Simulation of Queuing Systems with Random Parameters]. *Informatics and Automation*. 2024. vol. 23. no. 6. pp. 1577–1608. DOI: 10.15622/ia.23.6.1. (In Russ.).
34. Syed Z.A., Gummadi S., Mahima E.L., Naina S.R., Eswaran S., Honnavalli P. Performance Analysis Of 5G Network Slicing Simulations Using SimPy. *Proceedings of the 2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*. Bangalore, India: IEEE. 2022. pp. 1–6. DOI: 10.1109/CONECCT55679.2022.9865799.

35. Peyman M., Copado P., Panadero J., Juan A.A., Dehghanimohammadabadi M. A Tutorial on how to Connect Python with Different Simulation Software to Develop Rich Simheuristics. Proceedings of the 2021 Winter Simulation Conference (WSC). Phoenix, AZ, USA: IEEE, 2021. pp. 1–12. DOI: 10.1109/WSC52266.2021.9715511.
36. Nam S.H., Oh S.H., Yoon H.C., Cho Y.I., Cho K.Y., Kwak D.H., Woo J.H. Development of DES Application for Factory Material Flow Simulation with SimPy. Proceedings of the 2022 Winter Simulation Conference (WSC), Singapore. IEEE. 2022. pp. 1545–1556. DOI: 10.1109/WSC57314.2022.10015508.
37. Oszczyńska M., Ziolkowski J., Małachowski J. Redundancy allocation problem in repairable k-out-of-n systems with cold, warm, and hot standby: A genetic algorithm for availability optimization. Applied Soft Computing. 2024. vol. 165. DOI: 10.1016/j.asoc.2024.112041.
38. Oszczyńska M., Konwerski J., Ziolkowski J., Małachowski J. Reliability analysis and redundancy optimization of k-out-of-n systems with random variable k using continuous time Markov chain and Monte Carlo simulation. Reliability Engineering & System Safety. 2024. vol. 242. DOI: 10.1016/j.res.2023.109780.
39. Komari I.E., Fedorenko M., Kharchenko V., Yehorova Y., Bardis N., Lutai L. The neural modules network with collective relearning for the recognition of diseases: Fault-tolerant structures and reliability assessment. Neural Networks. 2020. vol. 1. DOI: 10.46300/9106.2020.14.102.
40. Kumar A., Saini M., Saini D.K., Badiwal, N. Cyber physical systems-reliability modelling: critical perspective and its impact. International Journal of System Assurance Engineering and Management. 2021. vol. 12. pp. 1334–1347. DOI: 10.1007/s13198-021-01305-6.
41. Lambropoulos G., Mitropoulos S., Douligeris C. Improving Business Performance by Employing Virtualization Technology: A Case Study in the Financial Sector. Computers. 2021. vol. 10. no. 4. DOI: 10.3390/computers10040052.
42. Shi F., Lin J. Virtual machine resource allocation optimization in cloud computing based on multiobjective genetic algorithm. Computational Intelligence and Neuroscience. 2022. vol. 2022. no. 1. DOI: 10.1155/2022/7873131.
43. Al-Dulaimi M.K.H., Al-Dulaimi O.M.K., Al-Dulaimi A.M.K., Alexandra M.O., Jihad N. Deep Learning for Wireless Network Distribution (5G/LTE). Proceedings of the 2023 4th International Conference on Communications, Information, Electronic and Energy Systems (CIEES). Plovdiv, Bulgaria: IEEE, 2023. pp. 1–6. DOI: 10.1109/CIEES58940.2023.10378816.
44. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Control of Multipath Transmissions in the Nodes of Switching Segments of Reserved Paths. International Conference on Information, Control, and Communication Technologies (ICCT). IEEE, 2022. pp. 1–5.
45. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. Reliability and Timeliness of Servicing Requests in Infocommunication Systems, Taking into Account the Physical and Information Recovery of Redundant Storage Devices. International Conference on Information, Control, and Communication Technologies (ICCT). IEEE, 2022. pp. 1–4.
46. Khomonenko A.D., Blagoveshchenskaya E.A., Prourzin O.V., Andruk A.A. [Forecasting the reliability of a cluster computing system using a semi-Markov model of alternating processes and monitoring]. High-tech technologies in space exploration of the Earth. 2018. vol. 10. no. 4. pp. 72–82. DOI: 10.24411/2409-5419-2018-10099. (In Russ.).
47. Sturley H., Fourmier A., Salcedo-Navarro A., Garcia-Pineda M., Segura-Garcia J. Virtualization vs. containerization, a comparative approach for application deployment in the continuum focused on the edge. Future Internet. 2024. vol. 16. no. 11.

48. Aniruddh M., Dinkar A., Mouli S.C., Sahana B., Deshpande A.A. Comparison of containerization and virtualization in cloud architectures. 2021 IEEE International conference on electronics, computing and communication technologies (CONECT). 2021. pp. 1–5.
49. Abuabdo A., Al-Sharif Z.A. Virtualization vs. containerization: towards a multithreaded performance evaluation approach. 2019 IEEE/ACS 16th international conference on computer systems and applications (AICCSA). 2019. pp. 1–6.
50. Kumar S. A brief study on virtualization and containerization. Cloud computing. 2022. pp. 37–46.
51. Xu J., Fortes J.A. Multi-objective virtual machine placement in virtualized data center environments. 2010 IEEE/ACM International conference on green computing and communications (GreenCom) and International conference on cyber, physical and social computing (CPSCom). 2010. pp. 179–188.
52. Khodosov M.A. Analiz tekhnologij virtualizacii [Analysis of virtualization technologies]. IIASU'23 – Iskusstvennyj intellekt v avtomatizirovannyh sistemah upravleniya i obrabotki dannyh: Sbornik statej II Vserossijskoj nauchnoj konferencii: v 5 t. [IIASU'23 – Artificial intelligence in automated control and data processing systems: Collection of articles of the II All-Russian Scientific Conference: in 5 volumes]. Moscow: KDU, Dobrosvet, 2024. vol. 4. pp. 475–481. DOI: 10.31453/kdu.ru.978-5-7913-1354-6-2024-488. (In Russ.).

Bogatyrev Vladimir — Ph.D., Dr.Sci., Professor of the faculty, Faculty of software engineering and computer technology, ITMO University; Professor of the department, Department of information security, St. Petersburg State University of Aerospace Instrumentation. Research interests: theory and methods of ensuring reliability, fault tolerance, and efficiency of computer systems and networks. The number of publications — 460. vladimir.bogatyrev@gmail.com; 49A, Kronverksky Ave., 197101, St. Petersburg, Russia; office phone: +7(812)232-5278.

Phung Van Quy — Ph.D. student, Faculty of software engineering and computer technology, ITMO University. Research interests: internet of Things system, reliability theory, queuing theory, fault tolerance, and efficiency of computer systems and networks. The number of publications — 5. phungvanquy97@gmail.com; 49A, Kronverksky Ave., 197101, St. Petersburg, Russia; office phone: +7(995)990-8193.

I. BYCHKOV, A. FEOKTISTOV, M. VOSKOBONIKOV, A. EDELEV,
N. BERESNEVA, O. EDELEVA
**OPTIMIZATION OF INTEGRATED ENERGY SYSTEM
RESILIENCE**

Bychkov I., Feoktistov A., Voskoboinikov M., Edelev A., Beresneva N., Edeleva O.
Optimization of Integrated Energy System Resilience.

Abstract. Currently, the development of approaches that enhance the resilience of integrated energy systems is a highly relevant research direction. Such approaches are based on the structural and parametric optimization of integrated energy systems. Typically, these approaches are closely tied to a specific spatio-temporal scope and a particular optimization method. The application of developed approaches at other scopes often leads to a significant increase in computation time and a possible reduction of solution accuracy. This problem is due to the complexity of energy system optimization models and the differences between them. To solve this problem, we have developed a methodology for selecting the most suitable methods for the design of system resilience at a given spatio-temporal scope. The proposed methodology is based on testing methods within a specialized testbed and a multi-criteria analysis of test results. The indicators for evaluating the methods include both summary metrics of resilience and efficiency parameters of computational resources. The benefits of the proposed methodology are illustrated for the resilient design with respect to national and local integrated energy systems. Several dozen methods from the well-known Parallel Global Multiobjective Optimizer library were efficiently tested in up to 10 hours. The analysis of the testing results was performed with different multi-criteria algorithms regarding the prioritization of the indicators.

Keywords: integrated energy systems, resilience enhancement, synthesis, structural and parametric optimization methods, multi-criteria analysis, testbed.

1. Introduction. Over the past two decades, problems caused by a series of extreme weather events, such as Superstorm Sandy (2012) and Hurricane Maria (2017), have highlighted the need for fundamental design and efficient operation of modern power systems. After extreme power failure events, the cost of restoring the power system becomes prohibitively high. This has a direct impact on the economic and social well-being of many countries. For example, in February 2021, three severe winter storms hit Texas, causing widespread failures in the power generation, transmission, and distribution subsystems [1]. The power outages led directly and indirectly to the deaths of approximately 200 people [2].

Recent research on blackouts has predominantly focused on integrated energy systems (IES) reliability [3]. Most of the world's reliable energy systems meet the so-called $n-1$ supply security criterion, which postulates that in the event of a system component failure, the power supply can be restored to consumers without load shedding. However, reliability-based IES designs fail to account for high-impact, low-probability (HILP) disruptions because the reliability concept is concerned with normal

operating conditions or controllable fault conditions. Designing a resilient IES is a challenging due to higher computational complexity.

In this paper, we propose a methodology for selecting optimization methods to solve the resilient IES design problem. Within the methodology, we test software developed to solve this problem to select the best optimization method for a particular class of IES models. The method selection is based on a multi-criteria analysis of two sets of indicators: resilience indicators, which are the summary metrics, and efficiency indicators for the use of computational resources. The proposed methodology is applicable to the design of IESs with different spatio-temporal scopes and the simultaneous modeling of different categories of disturbances

2. Related works

2.1. Energy system resilience. The resilience of an IES is defined as the ability of a system to anticipate, absorb, and mitigate the effects of the disturbances and recover from them rapidly. Under extreme conditions, the behavior of IES is described by resilience curves, each of which is a graph of the dependence of the system performance p on time t [4]. There are several ways to represent the resilience curves, such as the resilience triangle, resilience trapezoid, and multiphase resilience trapezoid [5].

The conceptual resilience trapezoid is shown in Fig. 1. From t_0 to t_1 , the system is in a stable initial state characterized by the performance level p_2 . When a disturbance occurs at t_1 , the system attempts to resist the degradation process by absorbing and counteracting the disturbance. The disturbance causes the system performance to drop to p_0 at t_2 . Between t_2 to t_3 the system mitigates to the consequences. From t_3 , the system aims to restore its functionality in the shortest possible time. The recovery process culminates at t_4 , with the system reaching a new stable state. The system then gradually increases its functionality at T to one of the levels $p_1 - p_3$.

Performance metrics mainly illustrate technological or territorial IES characteristics. In contrast, summary metrics [4] characterize different states of the system performance, as shown in Fig. 1. These states include planning (state 1), resistance (state 2), mitigation (state 3), and recovery (state 4). The planning, resistance, and mitigation states can be collectively referred to as adaptation. Issues related to the selection of the appropriate performance measures, summary metrics, and their standardization are discussed in detail in [4, 5].

The primary objective of IES resilience research is to identify a strategy for optimal disturbance resistance and rapid recovery. The strategy is a set of partially ordered activities that facilitate both adaptation and recovery.




Fig. 1. The conceptual resilience curve

In the existing, most approaches to enhance the resilience of IESs focus on only one of two key areas: the adaptation to disturbances, which are typically limited to a specific category, such as natural disasters, and the subsequent recovery of the system. The advantages of considering both key areas in an integrated manner are the balanced allocation of resources to enhance resilience and the significant reduction in performance losses during extreme conditions. The main drawback of that is increased computational complexity..

2.2. Energy system synthesis problem. In this paper, we consider the enhancement of IES resilience in the context of the problem of structural and parametric optimization of energy systems, which we refer to as energy system design (synthesis). Parametric optimization enables the selection of optimal parameters for the operation of energy equipment [6]. The objective of structural and parametric optimization is to select the most appropriate types of energy equipment and locations for their installation. In general, it is formulated on the basis of parametric optimization [7]. Therefore, from a mathematical and computational point of view, structural and parametric optimization is a more complex problem than parametric optimization.

The long-term reason for the resilient IES synthesis is a growing interest of consumers in exploring cleaner and more sustainable options for energy generation. This is driven by the increasing global demand for electricity and thermal energy, as well as the exhausted supplies of fossil fuels and their harmful effects on the environment.

The short-term reasons include modern consumption concepts such as demand-side management. It is commonly understood as controlled load shedding which is not designed for permanent demand reduction or the temporal shifting of energy demand within a predefined time window. Two main types of demand-side management response measures can be defined, namely curtailment and load shifting. Curtailment focuses on the reduction of load peaks. Load shifting leads to an advanced or postponed load catch-up during another point in time, e.g., when sufficient amounts of energy from other sources become available. Both measures make energy demand more flexible. The short-term factors are influenced not only by the consumer behavior but also by resilient dispatch strategies to combine distributed energy with traditional energy systems, cooperate with the operation of various forms of energy, and give play to the advantages and potential of different energy sources.

The traditional approach to IES synthesis entails the manual creation of numerous system configurations that are significantly different from each other. The primary disadvantage of this methodology is the high degree of subjectivity inherent in the decision-making process, which depends on the expertise and experience of the IES configuration designer.

The two-level nature of the synthesis problem provides the basis for two-level methodologies to address large-scale problems [8]. High-level methods coordinate equipment investment, placement, and sizing decisions, while low-level methods focus on making decisions about equipment unit operation. High-level optimization decisions must be made simultaneously with low-level ones. Thus, the computational complexity increases according to the level of the methodology.

At least two methodologies have been identified in the literature that leverage the characteristics of the automated IES synthesis problem. The superstructure-based synthesis consists of the following main sequential steps [9]:

- development of a superstructure containing all feasible alternative energy process structures;
- conversion of the superstructure into a mathematical programming program;
- computation of an optimal system configuration using the program.

At the same time, superstructure-free synthesis does not use the combinatorial search space to obtain alternative energy process structures. This methodology then dynamically generates these structures and subsequently evaluates them using an ESOM [10, 11].

Finally, in contrast to the traditional approach, both types of automated synthesis can result in a variety of IES configurations, which is a significant advantage for decision support. Decision makers typically prefer to obtain a number of promising IES configurations of high quality, which can then be evaluated in light of additional information that may emerge in practice. Consequently, an optimal but single IES configuration is often inadequate.

2.3. IES modelling complexity. The acquisition of the requisite set of IES configurations within an acceptable period of time represents a compromise between the computational costs, accuracy of computation, and the practical significance of the resulting data. In the existing literature, the following factors, which define the complexity of ESOMs, are highlighted:

- time-series aggregation (TSA) [12];
- spatial resolution [13];
- level of system behavior detailing;
- mathematical complexity.

Among these complexity factors, TSA level selection represents a crucial modeling decision. Equipment selection and sizing depend on performance within time series accurately representing expected operating conditions. These time series must include “typical periods” or “representative periods” that represent the most typical operating profiles. For a reliable and resilient IES design, the time series must include “extreme periods” that represent the most critical operating conditions, as the energy system supply inability often occurs under extreme conditions. The extreme periods reflect abnormal profiles that are maximally distant from the representative profiles and/or with close-to-peak or close-to-minimum values of selected facilities such as energy demand or production. In addition, it is important to define the minimum number of time periods, as this reduces the computational complexity of the IES synthesis at the TSA level [12].

The mathematical complexity is significantly influenced by the system detail factor. Mixed Integer Linear Programming (MILP) has been identified as the most suitable approach for IES design in terms of accuracy and runtime. However, Linear Programming (LP) and Non-Linear Programming (NLP) are also commonly employed in IES design. A prevalent approach for converting an NLP program into a MILP program is to apply the piecewise linearization procedure to non-linear curves.

The mathematical complexity factor plays a key role in determining the optimization methods to be used at each stage of the IES synthesis problem. The methods can be classified into two different categories: meta-heuristic and rigorous. In general, meta-heuristic methods are effective in obtaining optimal solutions in a relatively short time. However, these methods lack the ability to guarantee optimality due to the inconsistent and mathematically unproven nature of their convergence. Rigorous methods, on the other hand, are capable of finding exact solutions for a wide range of objective functions. However, they suffer from two major drawbacks: a high computational cost and potentially long computation time.

At the low level of the IES synthesis problem, rigorous optimization methods such as LP, MILP, NLP, or Mixed Integer Non-Linear Program (MINLP) are typically used to make decisions about equipment operation. Meta-heuristic methods are extensively used to make decisions about the selection, placement, and sizing of IES equipment, i.e. at the high level of the IES synthesis problem.

Table 1 shows the state of the art in IES structural and parametric optimization. The known approaches are grouped according to the following aspects: flexibility, reliability, and resilience [14]. The following parameters are used as evaluation criteria in Table 1:

- IES synthesis methodology c_1 (Traditional approach / Superstructure-based approach / Superstructure-free approach);
- ESOM geographical scope c_2 (National level / Regional level / Local level);
- TSA c_3 (Representative period / Extreme period);
- supply security criterion c_4 ($n-1 / n-k$);
- optimization method type c_5 for the first stages of the IES synthesis problem (Meta-heuristic / LP / MILP / NLP / MINLP);
- optimization method type c_6 for the second stages of the IES synthesis problem (Meta-heuristic / LP / MILP / NLP / MINLP);
- level of system behavior detailing c_7 (nonlinear investment curves / system dynamic).

In Table 1, the sign '+' means that there is support for a particular aspect within the approach. The '-' sign indicates the absence of support. If the information on an aspect is not clear, "N/A" is indicated. If the IES synthesis problem includes only one stage of its solution, "No stage" is indicated for the criteria c_6 .

As shown in Table 1, the searches conducted were based on the conventional structural and parametric optimization of IESs, with the

objective of enhancing flexibility, and exclusively considering representative periods. The exclusion of extreme periods from these searches can lead to the development of unreliable IESs.

Table 1. Approaches

Source	c_1	c_2	c_3	c_4	c_5	c_6	c_7
Flexibility							
[10]	-/-/+	+/-/-	+/-	N/A	+/-/-/-	-/-/-/+	-/+
[11]	-/-/+	+/-/-	+/-	N/A	+/-/-/-	-/-/-/+	-/+
[13]	+/-/-	+/+/>+	+/-	N/A	-/-/+/-	No stage	-/+
[15]	-/+/>-	+/-/-	+/-	N/A	-/-/-/+	No stage	-/+
[16]	+/-/-	+/-/-	+/-	N/A	-/-/+/-	No stage	-/+
[17]	-/+/>-	+/>++	+/-	N/A	-/-/+/-	-/+/>-/-	+/+
[18]	-/+/>-	+/-/-	+/-	N/A	+/-/-/-	-/-/-/+	+/+
[19]	-/+/>-	+/-/-	+/-	N/A	+/-/-/-	-/+/>-/-	+/+
[20]	+/-/-	+/-/-	+/-	N/A	-/-/-/+	No stage	-/-
[21]	+/-/-	+/>++	+/-	N/A	+/>-/-/-	No stage	-/-
Reliability							
[14]	-/+/>-	+/>++	-/+	+/-	-/-/+/-	-/+/>-/-	-/-
[22]	+/-/-	-/+/>-	+/-	N/A	-/-/+/-	-/+/>-/-	+/+
[23]	-/+/>-	+/>++	+/-	N/A	-/-/+/-	-/+/>-/-	+/+
[24]	+/-/-	-/+/>+	+/+	N/A	+/>-/-/-	No stage	-/-
Resilience							
[25]	-/+/>-	+/>+/-	+/+	N/A	+/-/-/-	-/+/>-/-	-/+
[26]	-/+/>-	+/>++	+/-	-/+	-/-/+/-	-/+/>-/-	-/-
[27]	-/+/>-	+/-/-	+/-	-/+	-/-/-/+	No stage	-/+
Our study	-/+/>-	+/>++	+/+	-/+	+/-/-/-	-/+/>-/-	+/+

In identifying the reliable IESs, the supply security criterion $n-1$ can be employed as an additional criterion. Extending the range of its values up to $n-k$ allows the design of resilient IESs. Thus, disturbance modeling, which simulates extreme periods and/or the failure of up to k IES elements according to the supply security criterion $n-k$, should be added to the structural and parametric optimization to enhance the system's resilience.

2.4. PaGMO library. A number of strategies have been developed to balance the spatial, temporal, technological, and economic resolution of the input data with the available computational resources in order to facilitate problem-solving within an acceptable time and with minimal loss of accuracy of the ESOMs. These strategies can be classified as either model-based or solver-based [28].

Evolutionary optimization methods are typically solver-based techniques. As an illustration, we will examine the Parallel Global Multiobjective Optimizer (PaGMO) library [29]. PaGMO is based on the asynchronous generalized islanding paradigm, which is expressed by the implementation of different data migration policies between individual threads. PaGMO includes an extensive set of optimization methods. Some of these methods are related to global optimization and use local optimization techniques. The aforementioned capabilities of PaGMO allow the creation of algorithms that use one or two optimization methods in each stream. The main advantage of PaGMO is that it provides a consolidated interface for interacting with metaheuristic methods and optimization packages, including Ipopt and NLOpt. Once this interface has been implemented, no further code modifications are required to replace optimization methods and add new ones that are not included in the library.

2.5. Summary. The IES synthesis methodologies described in Table 1 result in a variety of promising system configurations that improve the flexibility, reliability, or resilience aspect of a typical ESOM. A typical ESOM represents a class of IES with a given geographical scope, level of TSA, and detail of system behavior. In Table 1, most methodologies focus on the issues of TSA, spatial aggregation, and system behavior detail. In contrast, the goal of our work (the last row in Table 1) is to select and parameterize an optimization method that is capable of finding a set of resilient system configurations for any typical ESOM. All of the IES resilience enhancement methodologies described in Table 1 evaluate the efficiency of the selected equipment under a defined set of disturbance scenarios. This allows direct optimization methods to improve the resilience of the system under study.

Our approach, unlike others [25 – 27], can handle scenarios that mix extreme periods and failures according to the supply security criterion $n - k$. At the same time, this advantage can lead to increased computational cost and, most importantly, to the challenging problem of completing the IES synthesis process within an acceptable time. From the theoretical perspective represented in [30, 31], this problem can be solved by achieving a compromise between the typical ESOM hierarchy, optimization methods, and the cost determined by the available computational resources (Fig. 2).




Fig. 2. Achieving a compromise between a typical ESOM hierarchy, optimization methods, computational resources, and disturbance scenarios

3. Methodology for selecting optimization methods. The IES resilience enhancement problem involves determining the most efficient combination of activities for system adaptation and recovery under worst-case disturbance scenario:

$$\min_{j=1, n_w} \max_{i=1, n_v} \min_{x \in y(v_i, w_j)} f(x, v_i, w_j), \quad (1)$$

$$f(x, v, w) = \sum_{t=1}^{t_m} [(cx_t^v + bs_t^v) + a(y_t - y_t^v) + hw], \quad (2)$$

$$s_{t-1}^v + A^v x_t^v + Uq_t^v - y_t^v - s_t^v \geq 0, \quad (3)$$

$$x_t^v \leq d_t^v, \quad (4)$$

$$y_t^v \leq y_t \quad (5)$$

$$q_t^v \leq wq_t, \quad (6)$$

$$s_t^v \leq z_t^v, \quad (7)$$

$$z_0^v = s_0, \quad (8)$$

where v_i is a disturbance, n_v is a number of disturbances, w_j is a binary vector which nonzero component values activate an activity combination, n_w is a number of activity combinations,

- t_m is the number of modelling time periods,
- x_t^v is the decision vector, the elements of which characterize the operating parameters for the technological equipment of the IES,
- y_t^v is the decision vector, whose elements characterize the consumption of energy resources,
- q_t^v is the decision vector describing the usage intensity of the activities,
- s_t^v is the decision vector, whose components characterize the volumes of the fuel stocks,
- A^v is the matrix describing the production and transmission of energy resources under the impact of v ,
- d_t^v is the vector defining the technically possible limits of the IES equipment,
- y_t is the vector, which elements show the demand for energy resources,
- U is the matrix reflecting the localization of the implementation of the activities,
- q_t is the vector specifying the usage intensity limits of activities,
- z_t^v is the vector that defines the energy storage capacity,
- c is the vector, which elements determine the unit cost for each technological equipment type-size,
- b is the vector of unit costs for the energy storage operation,
- a is the vector of specific damages resulting from the shortage of certain energy resources,
- h is the vector specifying the unit cost of the preparation and implementation of activities.

The objective function (2) has three criteria. The first criterion reflects the cost associated with the IES operation. The second criterion includes metrics that estimate the cumulative energy resources shortage over t_m time periods. The third criterion characterizes the costs of preparation and implementation activities.

The effects of the disturbance v are realized by the matrix A^v and vectors d_t^v , z_t^v in equations (3), (4), and (7) respectively. Their elements characterize the deformation of different IES components due to the disturbance impact at the time t .

The level of necessary supply to consumers with certain energy resources is given by equation (3). The technical constraints of the activities are defined by (4).

The fuel volumes in stocks at time t are limited by their available capacities according to inequality (7). Equation (8) assumes that in the v at the initial time period $t=t_0$ all storages have an energy stock described by the vector s_0 .

Problem (1)-(8) describes the IES resilience optimization scheme (Fig. 3).

The supply security criterion $n-k$ defines the activity efficiency to enhance the IES resilience at the national level. In relevant disturbance scenarios, up to k elements from the list of the most important ones can be shut down simultaneously. The activity efficiency for the local-level IESs is determined for disturbances whose scenarios are modeled by 1 or more extreme periods.

The scheme of the resilient IES design solving (1) consists of three levels, as illustrated in Fig. 3.




Fig. 3. Resilient IES design scheme

At the top level, the equipment types, sizes, and locations described by the vector w_j are selected with a predefined optimization method. The

selected activities are then transferred to the lower levels. Subsequently, the operation of the selected equipment is evaluated under a defined set of disturbances.

The results of this evaluation are then passed to the intermediate level. At this level, the values of the resilience indicators that constitute the function f are calculated. The values are then returned to the top level, where they influence the next cycle of equipment selection. Evaluating the resilience of intermediate IES configurations, not just the resulting ones, facilitates the optimization process to improve system resilience.

In general, the high computational complexity of the scheme in Fig. 3 is determined by the complexity of the ESOM, the efficiency analysis of w_j , and the optimization method that is used at the top level. The correct choice of an optimization method has a significant impact on the ability to solve problem (1) in a reasonable time and on the accuracy of the solutions obtained. The vast majority of works on energy system synthesis do not consider the selection of an optimization method.

A comprehensive methodology for selecting optimization methods allows us to evaluate in practice the computational complexity of optimization methods from libraries such as PaGMO. We use a testbed to implement the scheme in Fig. 2 with optimization methods for testing and perform a multi-criteria analysis of the test results to rank the methods. In addition, the multi-criteria analysis is supported by expert analysis.

The methodology reflects the main stages of the qualimetry of models and polymodel complexes [30], which are preparing IES data for testing, defining evaluation indicators, performing optimization tests, and multi-criteria ranking methods.

3.1. IES data for testing. Before forming the set of disturbances for the resilient IES design, a preliminary vulnerability analysis should be performed to identify extreme periods and the most vulnerable elements of a studied IES.

The IES data for testing optimization methods differ from the original data in that the former simplifies the aspects not covered by the tests. For example, a set of realistic disturbance scenarios in the test variant can be replaced by a single disturbance that is practically unrealizable but guarantees the worst consequences for the basic configuration of the IES. This simplification speeds up the computational experiments.

3.2. Evaluation indicators. The list of the possible resilience indicators (Table 2) includes topological, functional, and economic summary metrics. The topological and functional indicators evaluate the efficiency of the activities.

The economic indicators characterize the cost of the activity combination. Topological indicators are effective in evaluating structural changes due to the failure of existing power facilities or the appearance of new facilities in the IES.

Functional indicators evaluate changes in the IES performance and characterize the energy flow distributions at the level of energy resource consumers. Economic indicators also depend on the IES performance and characterize cost changes that occur during the system recovery process.

Table 2. Resilience indicators

Indicator	Evaluation method	Evaluation aspects
IES performance	Integral evaluation of shortages in the analyzed time interval	Consumer categories and territorial affiliation
IES recovery	Comparison of the IES performance at the recovery stage	Consumer categories, territorial affiliation, and types of events
IES topological efficiency	Comparison of topological characteristics of the original and transformed IES configurations	Types (nodes and arcs) and connectivity of network elements
Damages due to disturbance impact	Integral damage evaluation on the analyzed time interval	Consumer categories and territorial affiliation
Costs of activities implementation	Integral cost evaluation in the analyzed time interval	Consumer categories, territorial affiliation, and types of events

The efficiency indicators for the use of computational resources characterize the time and computational cost of solving the IES resilience enhancement problem using different optimization methods (Table 3). The indicators values are stored in the testbed computation database.

Table 3. Efficiency indicators for the use of computational resources

Indicator	Units	Data source
Method execution time	Sec.	OProfile (a system-wide statistical profiling tool for Linux)
Average size of RAM used	MB	top (a task manager for Unix-like operating systems)
Average processor load	Percentages	top (a task manager for Unix-like operating systems)

3.3. Optimization tests. Our approach to the testing optimization methods involves creating a specialized computing environment. Compared to similar approaches, it has the following major advantages:

- use of testbed technologies with full support for High-Performance Computing (HPC);

- platform and language independence by isolating energy system frameworks in containers;
- development of the scientific workflow to execute the energy system frameworks;
- use of software module profilers to obtain the necessary hardware-dependent data for evaluating the computational complexity in ESOMs;
- support for several different algorithms for multi-criteria selection of the best optimization methods.

The advantage of our approach to constructing and using testbeds lies in unifying the development of both workflows and testbeds for testing these workflows. This allows us to significantly reduce the effort required to create a testbed and increase the efficiency of testing.

In our research, a testbed for service-oriented applications is implemented using the Framework for Development and Execution of Scientific WorkFlows (FDE-SWFs) [32] in the form of a workflow, including services for executing application and system software. The general structure of the testbed is shown in Fig. 4.

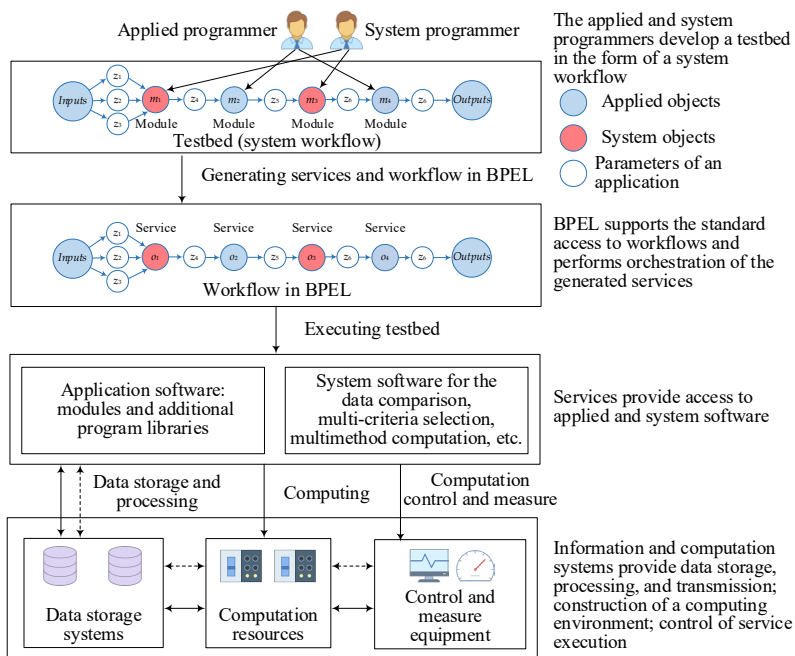


Fig. 4. Testbed structure

The testbed is created as a workflow, complemented by a set of system operations, and represented in Business Process Execution Language (BPEL). The workflow services execute tested application modules and the necessary system operations for processing and analyzing data and calculation results. The FDE-SWFs computation manager executes the workflow.

3.4. Optimization method ranks. Each of the testing n_m optimization methods results in $n_i, i + \overline{1, n_m}$ activity combinations which are evaluated with n_j indicators over n_g regions. The output of the method i evaluation for the region $g = \overline{1, n_g}$ is the matrix R_g^i of dimension $n_i \times n_j$.

Each matrix R_g^i is converted into the vector e_g^i of size n_j by the aggregation operation u :

$$e_g^i = u(R_g^i). \quad (9)$$

Depending on the chosen method selection strategy to obtain the guaranteed or potentially better result, the operation u in (2) selects either the minimum or maximum of the indicator values R_g^i or averages these values, $i + \overline{1, n_m}$. The vector e_g^i is analyzed using the multi-criteria analysis algorithm $l + \overline{1, n_a}$.

The output of the algorithm l is the rank vector $r_{g,l}^i$. These ranks allow us to evaluate the priority of each method for the region g .

4. Computational experiment. The testbed tests the application module executions for studying the IES resilience. The workflow that implements the testbed includes two application operations and seven system operations.

The applied operations generate a list of files with optimization method names and perform structural and parametric optimization using each method. The system operations are intended for data structuring and processing, as well as multi-criteria selecting the methods. The module execution is tested with different methods to solve an instance of a resilient IES synthesis problem.

The computation results of each module instance and the system metrics are combined into a parallel data list by system operations of the

workflow. Each parallel data list element corresponds to a distinct result variant.

Based on this list of the indicator values, the dedicated system operation for a multi-criteria selection generates a set of methods and proposes the most effective method among them, taking into account the ranking of these indicators. The initial data and computational experiment results are stored in the database by the computation manager.

The methods of the NLOpt library and the Ipopt solver package were additionally linked to the PaGMO library methods. In total, we have tested 62 methods. Most of them are evolutionary. During testing, we combined the following parameters of the methods: population size and number of generations. The values of the remaining method parameters were set by default in the PaGMO library.

The methods have been tested on a testbed in a distributed computing environment consisting of four nodes functioning under Ubuntu 22.04.1 LTS OS. Each of the nodes has the following characteristics: CPU AMD Ryzen 9 5950X, 128 GB of RAM, and 2 TB disk storage.

4.1. National IES. The typical ESOM of the national IES has the most aggregated level of spatial resolution [33]. At this level, large regions such as federal districts and separated energy facilities with the highest installed capacity are represented as nodes of energy transmission networks (Fig. 5). The smaller facilities have to be aggregated and considered by their combined average characteristics. The connections between the aggregated facilities within a node are neglected. The arcs in the energy transmission networks reflect the real connections between the most powerful objects or the connections between the different aggregated facilities. In this case study, there is only one disturbance scenario.

This scenario describes the disconnection of all consumers from the natural gas supply system network. All ruptured arcs are included in a redundant set of activities to enhance the resilience of the national IES.

In addition, new potential arcs between pairs of unconnected nodes are added to the redundant activity set. The distance between the unconnected nodes does not exceed a specified limit of 300 km. Pipe diameters are not specified. The capital cost of constructing new arcs is set equal to their length assuming that the construction investment for 1 km of all projected arcs is the same and does not depend on the terrain profile. Finally, there are over 3000 activities aimed at the national IES adaptation and recovery.

A tested method must either restore the existing gas supply network or propose a better system structure. Finally, 18 optimization methods were fully completed (Table 4) with the population size equal to 16, the number

of generations equal to 1000, and the time limit for solving the IES synthesis problem equal to 10 hours.




Fig. 5. The national-level IES model

The efficiency indicators for the use of computational resources are the execution time of optimization methods (Fig. 6(a)), the average amount of RAM usage (Fig. 6(b)), and the average CPU utilization (Fig. 6(c)) obtained by profiling the module execution. The metrics that measure the national IES resilience include the number of effective activities (Fig. 7(a)), the total length of new projected arcs (Fig. 7(b)), the natural gas supply metric (Fig. 7(c)), the electricity supply (Fig. 7(d)), and the heat supply (Fig. 7(e)). Fig. 7(b) also characterizes the investment value in new arcs.

Methods m3, m4, m12, m15, m17, and m18 significantly outperform other methods in execution time and average amount of RAM usage. At the same time, all methods m1-m18 show similar average processor load.

Table 4. Optimization methods for the national-level IES

Method code	Method name
m1	Particle Swarm Optimization
m2	Grey Wolf Optimizer
m3	(N+1)-ES Simple Evolutionary Algorithm
m4	Augmented Lagrangian Algorithm
m5	Non-dominated Sorting Genetic Algorithm
m6	Compass Search
m7	Simple Genetic Algorithm
m8	Particle Swarm Optimization Generational
m9	Self-adaptive DE (de_1220 aka pDE)
m10	Differential Evolution
m11	Self-adaptive DE (jDE and iDE)
m12	Multi-objective Improved Harmony Search
m13	Non-dominated Sorting PSO
m14	Compass Search
m15	Ipopt, Unconstrained Problem
m16	PRAXIS
m17	Single-objective Improved Harmony Search
m18	Ipopt, Constrained Problem

The number of activities to enhance the resilience of the national IES is sufficient to fully restore the energy supply to end-users of natural gas, heat, and electricity. Therefore, based on resilience criteria, only those methods are eligible for which the values of the indicators in Fig. 7(c), Fig. 7(d) and Fig. 7(e) have reached a value of 100%. However, in terms of potential investments (Fig. 7(b)), these methods did not perform as well as expected before the tests. It is assumed that the number of activated activities (Fig. 7(a)) would count in the hundreds. The solution to this problem may require a more precise parameterization of these methods.

Thus, based on resilience criteria, the most acceptable method for the national-level IES synthesis is m12 selected with the lexicographic multi-criteria selection algorithm. Another version of this method, namely m17, also approaches optimal performance. The lexicographic algorithm provides the ability to take into account the subject-area indicators used for prioritization into account. In terms of the efficiency indicators for the use of computational resources, the best method is m15.




Fig. 6. Efficiency indicators for the use of computational resources: a) method execution time; b) average size of RAM used; c) average processor load




Fig. 7. Metrics that measure the national IES resilience: a) activities; b) arcs length; c) natural supply; d) electricity supply; e) heat supply

3.2. Microgrid. The typical ESOM of a microgrid is characterized by the following features [34]: a microgrid is represented as a set of interacting energy hubs; an energy hub consists of the following elements: inputs and outputs, converters, and storages; hubs are interconnected to each other by energy distribution networks; only stable states of a microgrid are modeled.

In this case, we test a microgrid represented by a modernized energy supply system for a small village (population of 6000 people) located in the Baikal natural territory. The expected heat load is equal to 23.19 gcal/h, electric load is equal to 102.91 MWh per year. This is connected with the expected population growth and the need for reconstruction of energy supply facilities. Originally, the village has one combined heat and power (CHP) installation (energy source no. 1). For the future, it is considered to increase the capacity of the source no. 1 and to reconstruct the 62 sections of the heat supply network, including the construction of new sections and a pumping station. Two fuel supply options are considered when forming alternative microgrid structures: providing natural gas supply as a part of the local gasification program; and using wood chips purchased from a wood processing plant located near the village.

Four alternative structures were considered for upgrading the energy source no. 1: natural gas-fired boiler and CHP, wood chip-fired boiler and CHP. In the case of boilers, it is assumed that the village will purchase electricity from the external grid. In the case of CHPs, the equipment type-sizes were selected taking into account the full power self-supply of the village. Any excess power is sold to the external grid. The microgrid's extreme periods during the year are modeled by increasing the specified maximum demand for electricity and heat by 10% during the fall-winter period in the test version. The tested algorithm goes to the number of activities, which is equal to 0 or 1 as a result of the solution. Then it selects an activity from a given redundant set. When the population size is 1024, the number of generations is 20 and the time limit for solving the synthesis problem of the local-level IES is 1 h, 9 optimization methods were fully completed (Table 5).

The heat and power supply indicators obtained using the methods m4-m9 do not satisfy the limitations of the microgrid model. Therefore, we consider only methods m1-m3. The efficiency indicators for the use of computational resources are the execution time of optimization methods (Fig. 8(a)), the average amount of RAM usage (Fig. 8(b)), and the average CPU utilization (Fig. 8(c)). The summary metrics measuring the local IES resilience include the number of effective activities (Fig. 9(a)), investments (Fig. 9(b)), heat supply (Fig. 9(c)), and electricity supply (Fig. 9(d)).

Table 5. Optimization methods for microgrid

Method code	Method name
m1	Grey Wolf Optimizer
m2	Non-dominated Sorting GA II
m3	Covariance Matrix Adaptation Evo. Strategy
m4	Particle Swarm Optimization
m5	Simple Genetic Algorithm
m6	Particle Swarm Optimization Generational
m7	Self-adaptive DE (de 1220 aka pDE)
m8	Exponential Evolution Strategies
m9	(N+1)-ES Simple Evolutionary Algorithm

Method m3 significantly outperforms other methods in execution time and average amount of RAM usage. At the same time, all methods m1-m3 show similar average processor load. In terms of potential investments (Fig. 9(b)), the most profitable solution is proposed by method m3. However, from a resilience point of view, the most flexible solution to meet the increased heat demand (Fig. 9(c)) is proposed by the method m2. Based on resilience indicator prioritization, method m2 emerges as optimal for local-level IES synthesis when applying the lexicographic multi-criteria selection algorithm. In terms of computational resource efficiency, the best method is m3.




Fig. 8. Efficiency indicators for the use of computational resources: a) method execution time; b) average size of RAM usage; c) average processor load




Fig. 9. Metrics that measure the local IES resilience: a) activities; b) costs of thousand dollars; c) heat supply; d) electricity supply

5. Result discussion. We tested the solver-based ESOM acceleration strategy by varying the optimization methods on the top level of the resilient IES design scheme (Fig. 2). We performed the appropriate parameterization of the methods. We used the HiGHS solver, which supports parallelization in solving MILP problems, to compute the energy flows at the lower level of the resilience optimization scheme for both IES examples. The computational results prove that the specificity of IESs of different spatio-temporal scopes determines the composition of the superstructures and affects the selection of the best methods. In the case of a country, the superstructure includes the basic IES configuration and the designed arcs of one of the sectoral energy systems. The basic configuration consists of several dozen nodes connected by backbone lines for energy transport. The designed arcs form a redundant set of activities. Their activation is independent of each other. Therefore, statement (1) contains practically no logical conditions because of the high level of factor aggregation that determines the complexity of the ESOM. However, their computational complexity is high. This is due to the large dimension of the model itself and the significant size of the redundant set of the activities (about 5000). In this respect, we have deliberately chosen a large number of generations (more than 1000). This approach reliably generated required effective activity sets through the resilience optimization scheme. In the case of the microgrid, the high computational complexity of the optimization is determined by the maximum level of data granularity. The test results allow us to draw the following conclusion. For a successful operation of the

microgrid resilience optimization scheme under multiple logical conditions, and defining activity relations, it is necessary to dramatically increase the population size compared to the IES resilience optimization at the national level.

There is a wide range of optimization methods available. The selection of the most appropriate method among them is characterized by high computational complexity. This is due to the necessity of repeatedly running each method to calibrate its parameters by varying the combinations of their values. Therefore, specialists are often limited to a comparative analysis of a small number of methods (see, for example, the works [35, 36]). Generally, such limitations are due to the capabilities of the framework used to solve optimization problems and the characteristics of the available computing resources [36]. Unlike the above-mentioned works, FDE-SWFs provides the automation of the testbed creation. The testbed supports multi-method testing, parameter value generation, computational resource allocation, parallel execution, process monitoring, and data collection on IES resilience metrics and computational resource usage. Based on the results of the method runs, the testbed provides a multi-criteria selection of the best method taking into account different sets of indicators and their priorities.

6. Conclusions. We propose a new methodology for the selection of optimization methods used to solve the problem of the IES resilience enhancement at different spatio-temporal scopes. Within this approach, we have developed new models, algorithms, and application software for the IES modeling. We consider IESs as natural and technical systems, taking into account the detail of equipment and technological processes. Our developments also provide sensitivity of the modeling process to the size and degree of uncertainty of the spatio-temporal data. This methodology ensures that methods are selected at an acceptable time. The empirical study of the efficiency of the use of computational resources by optimization methods is carried out in parallel on the testbed using test datasets. The application of the methodology to the selection of optimization methods from the PaGMO library is successfully demonstrated in solving the resilience enhancement problem for two systems: the national-level IES and the microgrid supplying to the typical infrastructure object located in the Baikal natural territory.

The methodology can process numerous IES model classes. It is determined by the possible combinations of values of the factors listed in Table 1 and corresponding to the territorial and industrial levels of the Energy System Optimization Models hierarchy. These factors include ESOM geographical scope, time-series aggregation, optimization method

type for the first stages of the IES synthesis problem, and level of system behavior detailing.

We hope that specialists in the field of resilient IES design will in the future consider applying the proposed methodology in practice. However, there are several limitations of this methodology for selecting optimization methods. To reduce the complexity during the optimization method testing, our methodology first simplifies the system behavior and untested disturbance aspects. The completeness of the disturbance scenarios and their number affects the complexity of the IES synthesis (Fig. 2). We also simplify the IES model classes. Since they are solved as MILP problems in the lower level of the resilient IES design scheme, all production, storage, transfer, and conversion technologies have to be linearized. This approximation is valid as these technologies exhibit predominantly linear behavior.

References

1. Wu D., Zheng X., Xu Y., Olsen, D., Xia, B., Singh, C., Xie, L.: An open-source extendable model and corrective measure assessment of the 2021 Texas power outage. *Advances in Applied Energy*. 2021. vol. 4. pp. 100056. DOI: 10.1016/j.adapen.2021.100056.
2. Kemabonta T. Grid Resilience analysis and planning of electric power systems: The case of the 2021 Texas electricity crises caused by winter storm Uri (# TexasFreeze). *The Electricity Journal*. 2021. vol. 34(10). pp. 107044. DOI: 10.1016/j.tej.2021.107044.
3. Mancarella P. MES (multi-energy systems): An overview of concepts and evaluation models. *Energy*. 2014. vol. 65. pp. 1–17. DOI: 10.1016/j.energy.2013.10.041.
4. Poulin C.R., Kane M.B. Infrastructure resilience curves: Performance measures and summary metrics. *Reliability Engineering & System Safety*. 2021. vol. 216. pp. 107926. DOI: 10.1016/j.ress.2021.107926.
5. Dehghani A., Sedighizadeh M., Haghjoo F. An overview of the assessment metrics of the concept of resilience in electrical grids. *International Transactions on Electrical Energy Systems*. 2021. vol. 31(12). pp. e13159. DOI: 10.1002/2050-7038.13159.
6. Monakov Y., Tarasov A., Ivannikov A., Murzintsev, A., Shutenko, N. Optimization of equipment operation in power systems based on the use in the design of frequency-dependent models. *Energies*. 2023. vol. 16(18). pp. 6756. DOI: 10.3390/en16186756.
7. Karamov D.N., Suslov K.V. Structural optimization of autonomous photovoltaic systems with storage battery replacements. *Energy Reports*. 2021. vol. 7. pp. 349–358. DOI: 10.1016/j.egy.2021.01.059.
8. Wang L., Yang Z., Sharma S., et al. A review of evaluation, optimization and synthesis of energy systems: methodology and application to thermal power plants. *Energies*. 2018. vol. 12(1). pp. 73. DOI: 10.3390/en12010073.
9. Mencarelli L., Chen Q., Pagot A., Grossmann I.E. A review on superstructure optimization approaches in process system engineering. *Computers & Chemical Engineering*. 2020. vol. 136. pp. 106808. DOI: 10.1016/j.compchemeng.2020.106808.
10. Lin S., Zhao L., Deng S., Zhao D., Wang W., Chen M. Intelligent collaborative attainment of structure configuration and fluid selection for the Organic Rankine cycle. *Applied energy*. 2020. vol. 264. pp. 114743. DOI: 10.1016/j.apenergy.2020.114743.

11. Lazzaretto A., Manente G., Toffolo A. SYNTHSEP: A general methodology for the synthesis of energy system configurations beyond superstructures. *Energy*. 2018. vol. 147. pp. 924–949. DOI: 10.1016/j.energy.2018.01.075.
12. Hoffmann M., Priesmann J., Nolting L., Praktijnjo, A., Kotzur, L., Stolten, D. Typical periods or typical time steps? A multi-model analysis to determine the optimal temporal aggregation for energy system models. *Applied Energy*. 2021. vol. 304. pp. 117825. DOI: 10.1016/j.apenergy.2021.117825.
13. Reinert C., Nilges B., Baumgärtner N., Bardow A. This is SpArta: Rigorous optimization of regionally resolved energy systems by spatial aggregation and decomposition. *Applied Energy*. 2024. vol. 367. pp. 123323. DOI: 10.1016/j.apenergy.2024.123323.
14. Castelli A.F., Pilotti L., Monchieri A., Martelli E. Optimal design of aggregated energy systems with (n-1) reliability: MILP models and decomposition algorithms. *Applied Energy*. 2024. vol. 356. pp. 122002. DOI: 10.1016/j.apenergy.2023.122002.
15. Patin M., Bégot S., Gustin F., Lepiller V. Enhancing Residential Sustainability: Multi-objective optimization of hydrogen-based multi-energy system. *International Journal of Hydrogen Energy*. 2024. vol. 67. pp. 875–887. DOI: 10.1016/j.ijhydene.2023.12.201.
16. Gabrielli P., Furer F., Mavromatidis G., Mazzotti M. Robust and optimal design of multi-energy systems with seasonal storage through uncertainty analysis. *Applied Energy*. 2019. vol. 238. pp. 1192–1210. DOI: 10.1016/j.apenergy.2019.01.064.
17. Baumgärtner N., Bahl B., Hennen M., Bardow A. RiSES3: Rigorous Synthesis of Energy Supply and Storage Systems via time-series relaxation and aggregation. *Computers & Chemical Engineering*. 2019. vol. 127. pp. 127–139. DOI: 10.1016/j.compchemeng.2019.02.006.
18. Fazlollahi S., Maréchal F. Multi-objective, multi-period optimization of biomass conversion technologies using evolutionary algorithms and mixed integer linear programming (MILP). *Applied Thermal Engineering*. 2013. vol. 50(2). pp. 1504–1513. DOI: 10.1016/j.applthermaleng.2011.11.035.
19. Schmeling L., Schönfeldt P., Klement P., Vorspel L., Hanke B., von Maydell K., Agert C. A generalised optimal design methodology for distributed energy systems. *Renewable Energy*. 2022. vol. 200. pp. 1223–1239. DOI: 10.1016/j.renene.2022.10.029.
20. Honarmand H.A., Rashid S. M. A sustainable framework for long-term planning of the smart energy hub in the presence of renewable energy sources, energy storage systems and demand response program. *Journal of Energy Storage*. 2022. vol. 52. pp. 105009. DOI: 10.1016/j.est.2022.105009.
21. Tsvirkun A.D., Rezhnikov A.F., Dranko O.I., Kushnikov V.A., Bogomolov A.S. Optimization and simulation approach to determining critical combinations of company parameters. *Avtomatika i telemekhanika*. 2024. vol. 10. pp. 53–64. DOI: 10.31857/S0005231024100053. (In Russ.).
22. Maulén L., Castro M., Lorca Á., Negrete-Pincetic M. Optimization-based expansion planning for power and hydrogen systems with feedback from a unit commitment model. *Applied Energy*. 2023. vol. 343. pp. 121207. DOI: 10.1016/j.apenergy.2023.121207.
23. Cho S., Tovar-Facio J., Grossmann I.E. Disjunctive optimization model and algorithm for long-term capacity expansion planning of reliable power generation systems. *Computers & Chemical Engineering*. 2023. vol. 174. pp. 108243. DOI: 10.1016/j.compchemeng.2023.108243.
24. Teichgraber H., Küpper L.E., Brandt A.R. Designing reliable future energy systems by iteratively including extreme periods in time-series aggregation. *Applied Energy*. 2021. vol. 304. pp. 117696. DOI: 10.1016/j.apenergy.2021.117696.

25. Jing R., Wang X., Zhao Y., Zhou Y., Wu J., Lin J. Planning urban energy systems adapting to extreme weather. *Advances in Applied Energy*. 2021. vol. 3. pp. 100053. DOI: 10.1016/j.adapen.2021.100053.
26. Oster M.R., Amburg I., Chatterjee S., Eisenberg D.A., Thomas D.G., Pan F., Ganguly A.R. A tri-level optimization model for interdependent infrastructure network resilience against compound hazard events. *IEEE International Symposium on Technologies for Homeland Security (HST)*. IEEE. Boston. 2024. vol. 47. pp. 1–3. DOI: 10.1109/HST53381.2021.9619824.
27. Pfetsch M.E., Schmitt A. A generic optimization framework for resilient systems. *Optimization Methods and Software*. 2023. vol. 38(2). pp. 356–385. DOI: 10.1080/10556788.2022.2142581.
28. Cao K.K., Von Krbek K., Wetzel M., Cebulla F., Schreck S. Classification and evaluation of concepts for improving the performance of applied energy system optimization models. *Energies*. 2019. vol. 12(24). pp. 4656. DOI: 10.3390/en12244656.
29. Biscani F., Izzo D. A parallel global multiobjective framework for optimization: pagmo. *Journal of Open Source Software*. 2020. vol. 5(53). pp. 2338. DOI: 10.21105/joss.02338.
30. Mikoni S.V., Sokolov B.V., Yusupov R.M. *Kvalimetriya modeley i polimodel'nykh kompleksov [Qualimetry of Models and Polymodel Complexes]*. Moscow: RAS, 2018. 314 p. (In Russ.).
31. Valkman Y.R., Rykhalsky A.Y. Architecture of model parametric space: hierarchy in Simon's Architecture of Complexity. *Proceedings of the 2nd International Conference on Inductive Modelling (ICTM' 2008)*. Kyiv. 2008. pp. 58–59.
32. Danilov G., Voskoboinikov M. Testbed-based approach to testing a library for evaluating network reliability algorithms. *Proceedings of the International Workshop on Critical Infrastructures in the Digital World (IWCID-2024)*. Irkutsk, 2024. pp. 3–4.
33. Safonov G., Potashnikov V., Lugovoy O., Safonov M., Dorina A., Bolotov A. The low carbon development options for Russia. *Climatic Change*. 2020. vol. 162. pp. 1929–1945. DOI: 10.1007/s10584-020-02780-9.
34. Edeleva O., Edelev A., Voskoboinikov M., Feoktistov A. Scientific Workflow-Based Synthesis of Optimal Microgrid Configurations. *Energies*. 2024. vol. 17(23). pp. 1–25. DOI: 10.3390/en17236138.
35. Maulik A., Das D. Optimal operation of microgrid using four different optimization techniques. *Sustainable Energy Technologies and Assessments*. 2017. vol. 21. pp. 100–120. DOI: 10.1016/j.seta.2017.04.005.
36. Priesmann J., Nolting L., Praktikno A. Are complex energy system models more accurate? An intra-model comparison of power system optimization models. *Applied Energy*. 2019. vol. 255. pp. 113783. DOI: 10.1016/j.apenergy.2019.113783.

Bychkov Igor — Ph.D., Dr.Sci., Professor, Academician of RAS, Director, IDSTU SB RAS. Research interests: infocommunication technologies and computing systems, distributed computing and Grid-technologies, analysis and modeling of computer processes, mathematical methods in the theory of artificial intelligence and decision making. The number of publications — 522. idstu@icc.ru; 134, Lermontova St., 664033, Irkutsk, Russia; office phone: +7(3952)427-100.

Feoktistov Alexander — Ph.D., Dr.Sci., Associate Professor, Deputy director for scientific work, chief researcher, head of the laboratory, Laboratory of parallel and distributed computing systems, IDSTU SB RAS. Research interests: conceptual and computational models, parallel and distributed computing, scientific applications, simulation modeling, and testbeds.

The number of publications — 270. agf@icc.ru; 134, Lermontova St., 664033, Irkutsk, Russia; office phone: +7(3952)453-154.

Voskoboinikov Mikhail — Junior researcher, Laboratory of parallel and distributed computing systems, IDSTU SB RAS. Research interests: program engineering, distributed computing, service-oriented paradigm and testbeds. The number of publications — 29. mikev1988@icc.ru; 134, Lermontova St., 664033, Irkutsk, Russia; office phone: +7(3952)453-017.

Edelev Alexei — Senior researcher, Department of energy security, ESI SB RAS. Research interests: energy system modeling, decision support systems. The number of publications — 51. flower@isem.irk.ru; 130, Lermontova St., 664033, Irkutsk, Russia; office phone: +7(3952)500-646,,460.

Beresneva Natalia — Ph.D., Associate Professor, Researcher, Department of energy security, ESI SB RAS. Research interests: functioning of all Russia's energy sectors and issues of modeling interconnected energy systems. The number of publications — 44. beresneva@isem.irk.ru; 130, Lermontova St., 664033, Irkutsk, Russia; office phone: +7(3952)500-646,,454.

Edeleva Olga — Ph.D., Senior researcher, Department of pipeline energy systems, ESI SB RAS. Research interests: functioning of all Russia's energy sectors and issues of modeling interconnected energy systems. The number of publications — 50. edel@isem.irk.ru; 130, Lermontova St., 664033, Irkutsk, Russia; office phone: +7(3952)500-646,,329.

Acknowledgements. The study was supported by the Ministry of Science and Higher Education of the Russian Federation. Automation of development and use of applications, services, testbeds, and computing environment was implemented with the support of the project no. FWEU-2021-0005 «Technologies for the development and analysis of subject-oriented intelligent group control systems in non-deterministic distributed environments» (reg. no. 121032400051-9). The development of a methodology for selecting methods for optimizing multi-energy systems was carried out with the support of the projects no. FWEU-2021-0002 «Theoretical foundations, models and methods for managing the development and operation of intelligent energy heating systems» (reg. no. 121012090012-1) and no. FWEU-2021-0003 «Methodological foundations and modeling and instrumental means for studying energy security problems in the formation of fuel and energy complex development options» (reg. no. 121012090014-5).

И.В. Бычков, А.Г. Феоктистов, М.Л. Воскобойников, А.В. Еделев,
Н.М. Береснева, О.А. Еделева

ОПТИМИЗАЦИЯ ЖИВУЧЕСТИ ЭНЕРГЕТИЧЕСКИХ КОМПЛЕКСОВ

Бычков И.В., Феоктистов А.Г., Воскобойников М.Л., Еделев А.В., Береснева Н.М., Еделева О.А. Оптимизация живучести энергетических комплексов.

Аннотация. В настоящее время разработка подходов, повышающих живучесть энергетических комплексов, является весьма актуальным направлением исследований. Такие подходы основаны на структурной и параметрической оптимизации структуры исследуемой системы. Как правило, эти подходы тесно связаны с определенным пространственно-временным диапазоном и конкретным методом оптимизации. Применение разработанных подходов в иных диапазонах зачастую приводит к существенному увеличению времени вычислений и возможному снижению точности решения. Эта проблема обусловлена сложностью моделей оптимизации энергосистем и их различиями. Для решения этой проблемы нами разработана методология выбора наиболее подходящих методов проектирования живучих энергетических комплексов в заданном пространственно-временном диапазоне. Методология основана на методах тестирования в рамках специализированного испытательного стенда и многокритериальном анализе результатов испытаний. Критерии оценки методов включают как сводные метрики живучести, так и параметры эффективности вычислительных ресурсов. Проиллюстрированы преимущества методологии для проектирования живучих национальных и локальных энергетических комплексов. Несколько десятков методов из известной библиотеки Parallel Global Multiobjective Optimizer были эффективно протестированы в течение 10 часов. Анализ результатов тестирования проводился с использованием различных многокритериальных алгоритмов с учетом приоритетности критериев.

Ключевые слова: энергетические комплексы, повышение живучести, синтез, методы структурно-параметрической оптимизации, многокритериальный анализ, испытательный стенд.

Литература

1. Wu D., Zheng X., Xu Y., Olsen, D., Xia, B., Singh, C., Xie, L.: An open-source extendable model and corrective measure assessment of the 2021 Texas power outage. *Advances in Applied Energy*. 2021. vol. 4. pp. 100056. DOI: 10.1016/j.adapen.2021.100056.
2. Kemabonta T. Grid Resilience analysis and planning of electric power systems: The case of the 2021 Texas electricity crises caused by winter storm Uri (# TexasFreeze). *The Electricity Journal*. 2021. vol. 34(10). pp. 107044. DOI: 10.1016/j.tej.2021.107044.
3. Mancarella P. MES (multi-energy systems): An overview of concepts and evaluation models. *Energy*. 2014. vol. 65. pp. 1–17. DOI: 10.1016/j.energy.2013.10.041.
4. Poulin C.R., Kane M.B. Infrastructure resilience curves: Performance measures and summary metrics. *Reliability Engineering & System Safety*. 2021. vol. 216. pp. 107926. DOI: 10.1016/j.res.2021.107926.
5. Dehghani A., Sedighzadeh M., Haghjoo F. An overview of the assessment metrics of the concept of resilience in electrical grids. *International Transactions on Electrical Energy Systems*. 2021. vol. 31(12). pp. e13159. DOI: 10.1002/2050-7038.13159.

6. Monakov Y., Tarasov A., Ivannikov A., Murzintsev, A., Shutenko, N. Optimization of equipment operation in power systems based on the use in the design of frequency-dependent models. *Energies*. 2023. vol. 16(18). pp. 6756. DOI: 10.3390/en16186756.
7. Karamov D.N., Suslov K.V. Structural optimization of autonomous photovoltaic systems with storage battery replacements. *Energy Reports*. 2021. vol. 7. pp. 349–358. DOI: 10.1016/j.egyr.2021.01.059.
8. Wang L., Yang Z., Sharma S., et al. A review of evaluation, optimization and synthesis of energy systems: methodology and application to thermal power plants. *Energies*. 2018. vol. 12(1). pp. 73. DOI: 10.3390/en12010073.
9. Mencarelli L., Chen Q., Pagot A., Grossmann I.E. A review on superstructure optimization approaches in process system engineering. *Computers & Chemical Engineering*. 2020. vol. 136. pp. 106808. DOI: 10.1016/j.compchemeng.2020.106808.
10. Lin S., Zhao L., Deng S., Zhao D., Wang W., Chen M. Intelligent collaborative attainment of structure configuration and fluid selection for the Organic Rankine cycle. *Applied energy*. 2020. vol. 264. pp. 114743. DOI: 10.1016/j.apenergy.2020.114743.
11. Lazzaretto A., Manente G., Toffolo A. SYNTHSEP: A general methodology for the synthesis of energy system configurations beyond superstructures. *Energy*. 2018. vol. 147. pp. 924–949. DOI: 10.1016/j.energy.2018.01.075.
12. Hoffmann M., Priesmann J., Nolting L., Praktiknjo, A., Kotzur, L., Stolten, D. Typical periods or typical time steps? A multi-model analysis to determine the optimal temporal aggregation for energy system models. *Applied Energy*. 2021. vol. 304. pp. 117825. DOI: 10.1016/j.apenergy.2021.117825.
13. Reinert C., Nilges B., Baumgärtner N., Bardow A. This is SpArta: Rigorous optimization of regionally resolved energy systems by spatial aggregation and decomposition. *Applied Energy*. 2024. vol. 367. pp. 123323. DOI: 10.1016/j.apenergy.2024.123323.
14. Castelli A.F., Pilotti L., Monchieri A., Martelli E. Optimal design of aggregated energy systems with (n-1) reliability: MILP models and decomposition algorithms. *Applied Energy*. 2024. vol. 356. pp. 122002. DOI: 10.1016/j.apenergy.2023.122002.
15. Patin M., Bégot S., Gustin F., Lepiller V. Enhancing Residential Sustainability: Multi-objective optimization of hydrogen-based multi-energy system. *International Journal of Hydrogen. Energy*. 2024. vol. 67. pp. 875–887. DOI: 10.1016/j.ijhydene.2023.12.201.
16. Gabrielli P., Fürer F., Mavromatidis G., Mazzotti M. Robust and optimal design of multi-energy systems with seasonal storage through uncertainty analysis. *Applied Energy*. 2019. vol. 238. pp. 1192–1210. DOI: 10.1016/j.apenergy.2019.01.064.
17. Baumgärtner N., Bahl B., Hennen M., Bardow A. RiSES3: Rigorous Synthesis of Energy Supply and Storage Systems via time-series relaxation and aggregation. *Computers & Chemical Engineering*. 2019. vol. 127. pp. 127–139. DOI: 10.1016/j.compchemeng.2019.02.006.
18. Fazlollahi S., Maréchal F. Multi-objective, multi-period optimization of biomass conversion technologies using evolutionary algorithms and mixed integer linear programming (MILP). *Applied Thermal Engineering*. 2013. vol. 50(2). pp. 1504–1513. DOI: 10.1016/j.applthermaleng.2011.11.035.
19. Schmeling L., Schönfeldt P., Klement P., Vorspel L., Hanke B., von Maydell K., Agert C. A generalised optimal design methodology for distributed energy systems. *Renewable Energy*. 2022. vol. 200. pp. 1223–1239. DOI: 10.1016/j.renene.2022.10.029.
20. Honarmand H.A., Rashid S. M. A sustainable framework for long-term planning of the smart energy hub in the presence of renewable energy sources, energy storage systems and demand response program. *Journal of Energy Storage*. 2022. vol. 52. pp. 105009. DOI: 10.1016/j.est.2022.105009.
21. Tsvirkun A.D., Rezhnikov A.F., Dranko O.I., Kushnikov V.A., Bogomolov A.S. Optimization and simulation approach to determining critical combinations of

- company parameters. *Avtomatika i telemekhanika*. 2024. vol. 10. pp. 53–64. DOI: 10.31857/S0005231024100053. (In Russ.).
22. Maulén L., Castro M., Lorca Á., Negrete-Pincetic M. Optimization-based expansion planning for power and hydrogen systems with feedback from a unit commitment model. *Applied Energy*. 2023. vol. 343. pp. 121207. DOI: 10.1016/j.apenergy.2023.121207.
 23. Cho S., Tovar-Facio J., Grossmann I.E. Disjunctive optimization model and algorithm for long-term capacity expansion planning of reliable power generation systems. *Computers & Chemical Engineering*. 2023. vol. 174. pp. 108243. DOI: 10.1016/j.compchemeng.2023.108243.
 24. Teichgraeber H., Küpper L.E., Brandt A.R. Designing reliable future energy systems by iteratively including extreme periods in time-series aggregation. *Applied Energy*. 2021. vol. 304. pp. 117696. DOI: 10.1016/j.apenergy.2021.117696.
 25. Jing R., Wang X., Zhao Y., Zhou Y., Wu J., Lin J. Planning urban energy systems adapting to extreme weather. *Advances in Applied Energy*. 2021. vol. 3. pp. 100053. DOI: 10.1016/j.adapen.2021.100053.
 26. Oster M.R., Amburg I., Chatterjee S., Eisenberg D.A., Thomas D.G., Pan F., Ganguly A.R. A tri-level optimization model for interdependent infrastructure network resilience against compound hazard events. *IEEE International Symposium on Technologies for Homeland Security (HST)*. IEEE. Boston. 2024. vol. 47. pp. 1–3. DOI: 10.1109/HST53381.2021.9619824.
 27. Pfetsch M.E., Schmitt A. A generic optimization framework for resilient systems. *Optimization Methods and Software*. 2023. vol. 38(2). pp. 356–385. DOI: 10.1080/10556788.2022.2142581.
 28. Cao K.K., Von Krbek K., Wetzel M., Cebulla F., Schreck S. Classification and evaluation of concepts for improving the performance of applied energy system optimization models. *Energies*. 2019. vol. 12(24). pp. 4656. DOI: 10.3390/en12244656.
 29. Biscani F., Izzo D. A parallel global multiobjective framework for optimization: pagmo. *Journal of Open Source Software*. 2020. vol. 5(53). pp. 2338. DOI: 10.21105/joss.02338.
 30. Микони С.В., Соколов Б.В., Юсупов Р.М. Квалиметрия моделей и полимодельных комплексов: Монография М.: Изд-во РАН, 2018. 314 с.
 31. Valkman Y.R., Rykhalsky A.Y. Architecture of model parametric space: hierarchy in Simon's Architecture of Complexity. *Proceedings of the 2nd International Conference on Inductive Modelling (ICTM' 2008)*. Kyiv. 2008. pp. 58–59.
 32. Danilov G., Voskoboinikov M. Testbed-based approach to testing a library for evaluating network reliability algorithms. *Proceedings of the International Workshop on Critical Infrastructures in the Digital World (IWCI-2024)*. Irkutsk, 2024. pp. 3–4.
 33. Safonov G., Potashnikov V., Lugovoy O., Safonov M., Dorina A., Bolotov A. The low carbon development options for Russia. *Climatic Change*. 2020. vol. 162. pp. 1929–1945. DOI: 10.1007/s10584-020-02780-9.
 34. Edeleva O., Edelev A., Voskoboinikov M., Feoktistov A. Scientific Workflow-Based Synthesis of Optimal Microgrid Configurations. *Energies*. 2024. vol. 17(23). pp. 1–25. DOI: 10.3390/en17236138.
 35. Maulik A., Das D. Optimal operation of microgrid using four different optimization techniques. *Sustainable Energy Technologies and Assessments*. 2017. vol. 21. pp. 100–120. DOI: 10.1016/j.seta.2017.04.005.
 36. Priesmann J., Nolting L., Praktiknjo A. Are complex energy system models more accurate? An intra-model comparison of power system optimization models. *Applied Energy*. 2019. vol. 255. pp. 113783. DOI: 10.1016/j.apenergy.2019.113783.

Бычков Игорь Вячеславович — д-р техн. наук, профессор, академик РАН, директор, ИДСТУ СО РАН. Область научных интересов: инфокоммуникационные технологии и

вычислительные системы, распределенные вычисления и Grid-технологии, анализ и моделирование компьютерных процессов, математические методы в теории искусственного интеллекта и принятия решений. Число научных публикаций — 522. idstu@icc.ru; улица Лермонтова, 134, 664033, Иркутск, Россия; р.т.: +7(3952)427-100.

Феокистов Александр Геннадьевич — д-р техн. наук, доцент, заместитель директора по научной работе, главный научный сотрудник, заведующий лабораторией, лаборатория параллельных и распределенных вычислительных систем, ИДСТУ СО РАН. Область научных интересов: распределенные вычисления, мультиагентные технологии, имитационное моделирование. Число научных публикаций — 270. agf@icc.ru; улица Лермонтова, 134, 664033, Иркутск, Россия; р.т.: +7(3952)453-154.

Воскобойников Михаил Леонтьевич — младший научный сотрудник, лаборатория параллельных и распределенных вычислительных систем, ИДСТУ СО РАН. Область научных интересов: программная инженерия, распределенные вычисления, сервис-ориентированный подход, испытательные стенды. Число научных публикаций — 29. mikev1988@icc.ru; улица Лермонтова, 134, 664033, Иркутск, Россия; р.т.: +7(3952)453-017.

Еделев Алексей Владимирович — старший научный сотрудник, отдел энергетической безопасности, ИСЭМ СО РАН. Область научных интересов: моделирование энергетических систем, системы поддержки принятия решений. Число научных публикаций — 51. flower@isem.irk.ru; улица Лермонтова, 130, 664033, Иркутск, Россия; р.т.: +7(3952)500-646.,460.

Береснева Наталья Михайловна — канд. техн. наук, доцент, научный сотрудник, отдел энергетической безопасности, ИСЭМ СО РАН. Область научных интересов: функционирование энергетики России, моделирование взаимосвязанных энергетических систем. Число научных публикаций — 44. beresneva@isem.irk.ru; улица Лермонтова, 130, 664033, Иркутск, Россия; р.т.: +7(3952)500-646.,454.

Еделева Ольга Алексеевна — канд. техн. наук, старший научный сотрудник, отдел трубопроводных систем энергетики, ИСЭМ СО РАН. Область научных интересов: функционирование энергетики России, моделирование взаимосвязанных энергетических систем. Число научных публикаций — 50. edel@isem.irk.ru; улица Лермонтова, 130, 664033, Иркутск, Россия; р.т.: +7(3952)500-646.,329.

Поддержка исследований. Исследование выполнено при поддержке Министерства науки и высшего образования Российской Федерации. Автоматизация разработки и применения приложений, сервисов, испытательных стендов и вычислительной среды выполнена при поддержке проекта № FFEW-2021-0005 «Технологии разработки и анализа предметно-ориентированных интеллектуальных систем группового управления в недетерминированных распределенных средах» (рег. № 121032400051-9). Разработка методологии выбора методов оптимизации мультиэнергетических систем осуществлена при поддержке проектов № FFEU-2021-0002 «Теоретические основы, модели и методы управления развитием и функционированием интеллектуальных трубопроводных систем энергетики» (рег. № 121012090012-1) и № FFEU-2021-0003 «Методические основы и модельно-инструментальные средства исследования проблем энергетической безопасности при формировании вариантов развития ТЭК» (рег. № 121012090014-5).

M. IDRISSE ALAMI, A. EZ-ZAHOUT, F. OMARY
**COMPARATIVE STUDY OF PERSON RE-IDENTIFICATION
TECHNIQUES BASED ON DEEP LEARNING MODELS**

Idrissi Alami M., Ez-zahout A., Omary F. Comparative Study of Person Re-Identification Techniques Based on Deep Learning Models.

Abstract. Person re-identification (Re-ID) is crucial in intelligent surveillance, requiring precise identification of individuals across multiple camera viewpoints. Traditional distance-based methods, such as Euclidean and Cosine, struggle with challenges like posture variations and occlusions, limiting their effectiveness. This study explores deep metric learning models, specifically Siamese and Triplet networks, to improve Re-ID performance. We evaluate these methods on the Market-1501 dataset using Cumulative Matching Characteristic (CMC) and Cumulative Distribution Function (CDF) curves. Our findings reveal that the Triplet network outperforms traditional approaches at higher ranks, achieving Rank-5 accuracy of 78.6% and Rank-10 accuracy of 93%, while its Rank-1 accuracy remains low (0.06%). In contrast, Euclidean and Cosine distances show poor Rank-1 performance (2% and 0.30%, respectively), highlighting their limitations. Additionally, incorporating VGG16 enhances feature extraction, improving recognition by capturing fine-grained spatial details. This comparative study highlights the effectiveness of deep metric learning and underscores its potential for real-world surveillance applications. However, the computational demands of deep networks present challenges for real-time deployment. Future research should focus on optimizing model efficiency, reducing computational costs, and extending evaluations to real-time scenarios.

Keywords: CMC/CDF metrics, convolutional neural networks (CNNs), deep learning, person re-identification, VGG16, video surveillance systems.

1. Introduction. Video surveillance systems progress through four fundamental stages: Detection, Tracking, Profile Analysis, and Re-Identification (Re-ID). Detection acts as the base by recognizing humans or things inside a monitored region, enabling additional analysis and tracking [1]. Tracking tracks subjects across scenes or cameras, maintaining continuity. Profile Analysis captures crucial aspects such as looks and behavior for identification. Re-ID links humans across sites, which is important for seamless surveillance. Together, these strategies increase accuracy, especially in busy settings and complicated security setups [2].

Person re-identification (re-ID) is a crucial problem in video surveillance systems, concentrating on identifying individuals across different camera viewpoints. The ability to precisely re-identify someone has important ramifications for security, forensic investigations, and monitoring applications. Despite tremendous development in this sector, achieving high accuracy remains a problem due to changes in appearance, stance, lighting conditions, and occlusions [3].

Early person re-identification algorithms generally relied on handcrafted feature representations and simple distance metrics such as Euclidean distance, cosine similarity, and Mahalanobis distance. The

Euclidean distance, one of the simplest metrics, calculates the straight-line distance between feature vectors, making it computationally efficient but ineffectual for complicated variations in surveillance scenarios [4]. Similarly, cosine similarity is widely used for high-dimensional feature spaces, measuring the angular difference between feature vectors rather than absolute distances. However, it struggles to provide correct matches at Rank-1 and exhibits reduced accuracy at Rank-5 [5]. The Mahalanobis distance contains covariance information to account for correlations between features, exhibiting greater performance in some scenarios, such as fluctuating lighting and background clutter [6, 7]. However, these methods alone often fail to generalize well across different datasets and environmental conditions.

To circumvent these constraints, deep learning algorithms, particularly Convolutional Neural Networks (CNNs), have been widely adopted due to their capacity to learn hierarchical and discriminative feature representations directly from images [5, 8]. Prominent CNN architectures, including VGG16, ResNet, and Inception, have significantly boosted person re-identification performance. Specifically, VGG16 has exhibited exceptional results in image classification, transfer learning, and capturing detailed spatial characteristics beneficial for re-identification [6, 9, 10, 11]. However, its deep structure demands substantial computational resources, prompting the investigation of more efficient architectures such as ResNet and Inception [7, 12]. Additionally, deep learning advancements have fostered the development of metric learning frameworks like Siamese and Triplet networks, which have proven effective in distinguishing individuals with similar appearances across different camera perspectives [8].

Beyond standard CNNs, metric learning-based techniques such as Siamese networks and Triplet networks have significantly boosted re-identification performance. Siamese networks leverage contrastive loss to learn a feature space where related identities are clustered together while distinct identities are pushed apart [13]. While they outperform traditional distance metrics at higher ranks (e.g., Rank-5), they still struggle at Rank-1 [14]. Triplet networks improve this principle by including anchor-positive-negative triplets, guaranteeing that positive samples are closer to the anchor than negative samples. This strategy considerably improves accuracy at Rank-5 and Rank-10 but involves complex training procedures and large-scale labeled data [15].

For evaluation, the Market-1501 dataset has become a typical benchmark for person re-identification, presenting realistic surveillance scenarios with problems such as illumination fluctuations, occlusions, and backdrop complexity [15, 16]. Performance assessment often depends on

metrics such as the Cumulative Matching Characteristic (CMC) and the Cumulative Distribution Function (CDF), which provide rank-based and distributional insights into algorithm efficacy [17].

Despite breakthroughs in re-identification, problems exist, including domain adaptability, occlusions, computing limits, and privacy issues [18]. This study rigorously assesses various re-identification techniques – Euclidean, Cosine, Mahalanobis, Siamese, and Triplet networks – across standard datasets and rank-based criteria. By assessing their strengths and limits in diverse surveillance contexts, we propose modifications to deep learning-based techniques to enhance accuracy while maintaining efficiency.

In recent years, state-of-the-art person re-identification models particularly those based on Vision Transformers and hybrid CNN-ViT [15, 22] architectures have achieved over 95% Rank-1 accuracy on the Market-1501 benchmark. Despite these advancements, many of these models demand substantial computational resources, limiting their applicability in lightweight or real-time systems. In contrast, our study investigates a Triplet-based model leveraging VGG16, which, while achieving modest Rank-1 accuracy, demonstrates competitive performance at higher ranks (Rank-5 and Rank-10), making it a candidate for scalable and efficient re-identification pipelines (Table 1).

Table 1. Comparative Performance of Resent Person Re-ID Models on Market-1501

Model	Dataset	Rank-1	Rank-5	Rank-10	Notes
Our Triplet Net 2025	Market-1501	0.06%	78.6%	93%	VGG16 based
Squeeze-Net + DAE 2021 [20]	Market-1501	86.2%	92.4%	96.1%	Hybred CNN
TransReID 2023 [21]	Market-1501	95.2%	-	-	ViT-based
CNN-ViT-Loss 2025 [15]	Market-1501	93.5%	96.2%	97.4%	ViT and Loss Based
UntransReID 2024 [22]	Market-1501	95.7	-	-	Transformer based

Our study demonstrates that Triplet networks significantly outperform traditional distance metrics, achieving Rank-10 accuracy of 93%, thus contributing valuable insights into the practical deployment of intelligent surveillance systems.

The findings contribute to the continuing discourse on intelligent video surveillance, suggesting effective ways for robust and scalable human re-identification.

2. Method

2.1. Data Source. The evaluation in this work leverages the widely famous Market-1501 dataset as the core dataset for individual re-identification. Market-1501 is a benchmark dataset specifically created for person re-identification tasks in video surveillance systems. It consists of high-resolution photos acquired from six cameras in an outside location, simulating real-world problems such as differences in lighting conditions, occlusions, and varied views [15, 16].

Each individual in the collection appears in several photographs under varied situations, offering a diversified and demanding re-identification job. The dataset is separated into training and testing sets, with ground truth annotations provided, including identification labels and bounding boxes. These labels assist performance evaluation using common metrics such as Cumulative Matching Characteristics (CMC) and Cumulative Distribution Function (CDF).

2.2. Preprocessing and Feature Extraction. Before training our deep learning models, rigorous preprocessing steps are applied to ensure consistency and maximize model performance. Initially, all raw input images are resized uniformly to dimensions of 224×224 pixels, compatible with the input requirements of deep CNN architectures. To ensure effective training, pixel values are then scaled through normalization to fall within the range $[0, 1]$, significantly enhancing the convergence stability and effectiveness of the training process. Moreover, we apply various data augmentation strategies – including random cropping, horizontal flipping, and brightness adjustments – to simulate real-world variations and further improve the robustness and generalization capabilities of our models.

For feature extraction, we leverage the well-established VGG16 architecture, pre-trained on the extensive ImageNet dataset [23]. This choice is justified by VGG16's demonstrated capability to capture rich hierarchical representations, effectively encoding discriminative characteristics such as clothing patterns, textures, and body shapes, crucial for distinguishing individuals. Specifically, we extract high-level feature vectors from the fully connected (FC) layer preceding the final softmax layer, thereby obtaining compact 128-dimensional embeddings suitable for distance-based metric learning.

These extracted embeddings are then systematically integrated into our deep learning-based re-identification frameworks, specifically Siamese and Triplet Networks. The Siamese network uses these embeddings to construct query-gallery image pairs, optimizing similarity predictions via binary cross-entropy loss, while the Triplet network processes image triplets (anchor-positive-negative), optimizing relative distances through the triplet

loss. Both networks utilize the Adam optimizer with a learning rate of 0.0001, batch normalization, dropout regularization, and a batch size of 16. The learned representations are ultimately evaluated using Euclidean distance metrics, with results visualized through Cumulative Matching Characteristic (CMC) curves and Cumulative Distribution Function (CDF) plots.

2.3. Distance Metrics. In the realm of people re-identification, the choice of distance metric is pivotal for accurately quantifying the similarity between feature vectors. We evaluate several widely used metrics in this context:

– **Euclidean distance** between two feature vectors, **X** and **Y**, is computed as follows:

$$D_{Euclidean}(X, Y) = \sqrt{\sum_{i=1}^n (X_i - Y_i)^2}, \quad (1)$$

– **Cosine distance** measures the cosine of the angle θ between two feature vectors, **X** and **Y**, in a high-dimensional space:

$$D_{Cosine}(X, Y) = \frac{\sum_{i=1}^n X_i \cdot Y_i}{\sqrt{\sum_{i=1}^n X_i^2} \cdot \sqrt{\sum_{i=1}^n Y_i^2}}, \quad (2)$$

– **Mahalanobis distance** between feature vectors **X** and **Y** is defined as:

$$D_{Mahalanobis}(X, Y) = \sqrt{(X - Y)^T \cdot C^{-1} \cdot (X - Y)}, \quad (3)$$

where **C** is the covariance matrix.

– **Siamese networks** utilize a neural network architecture to learn a similarity metric. The loss function for Siamese networks can be expressed as:

$$L_{Siamese}(X, Y, S) = \frac{1}{2}(1 - S) \cdot D_{Euclidean}(X, Y)^2 + \frac{1}{2}S \cdot \max(0, m - D_{Euclidean}(X, Y)^2), \quad (4)$$

where **S** is the binary similarity label, and **m** is the margin.

– **Triplet networks** optimize the embedding space by minimizing the distance between similar images and maximizing the distance between dissimilar ones. The triplet loss function is defined as:

$$L_{Triplet}(A, P, N) = \max(0, D_{Euclidean}(A, P) - D_{Euclidean}(A, N) + \alpha), \quad (5)$$

where A, P, and N represent anchor, positive, and negative samples, respectively, and α is the margin.

These distance metrics serve as fundamental components in our evaluation, contributing to the robustness and effectiveness of our intelligent video surveillance system.

2.4. Deep Learning Models and Training. We integrate the VGG16 architecture to extract high-level features from person images. The deep learning model enhances the system's ability to capture intricate patterns and representations, contributing to improved re-identification accuracy [24].

We train deep learning-based person re-identification models using both Siamese and Triplet Networks, each optimizing feature similarity differently:

The Siamese Network is designed to compare pairs of images by concatenating the feature vectors of a query and gallery image [25]. This concatenated representation is passed through fully connected layers with 512 and 256 neurons, followed by a sigmoid activation function to predict similarity. The network is trained using binary cross-entropy loss and optimized with Adam at a learning rate of 0.0001. To improve generalization and prevent overfitting, batch normalization and dropout are applied. Training is conducted with a batch size of 16, and a data generator is employed to efficiently construct query-gallery image pairs. Performance is measured by Euclidean distance calculations and Cumulative Matching Characteristic (CMC) curves.

The Triplet Network expands the learning paradigm by processing triplets consisting of an anchor, a positive, and a negative sample [26]. The model is trained using triplet loss, guaranteeing that the distance between an anchor and a positive sample (same identity) is minimized, while the distance between an anchor and a negative sample (different identity) is maximized. The architecture consists of fully connected layers with 512 and 256 neurons, followed by a sigmoid activation function. Similar to the Siamese Network, Adam optimizer is used, with a batch size of 16. The learned embeddings are evaluated using pairwise Euclidean distance metrics, and performance is visualized through CMC curves and Cumulative Distribution Function (CDF) plots.




Fig. 1. Deep Learning Model based on Siamese Network




Fig. 2. Deep Learning Model based on Triplet Network

2.5. Evaluation Metrics. We assess the performance using Cumulative Matching Characteristics (CMC) and Cumulative Distribution Function (CDF) metrics. CMC illustrates the probability of correct identification within the top-k ranked matches, while CDF provides a cumulative distribution of matching scores [17, 27].

– **Cumulative Matching Characteristics (CMC):** Measures the probability of correctly identifying a person within the top-k matches, the *CMC* curve is formulated as follows:

$$CMC(k) = \frac{NumCIR \leq k}{TNQ}, \quad (6)$$

where: *NumCIR* – number of correct identifications at rank, *TNQ* – total number of queries, *k* – the rank of the match.

– **Cumulative Distribution Function (CDF):** Provides a statistical overview of matching score distributions, the CDF curve is formulated as follows:

$$CDF(s) = \frac{NumQMS \leq s}{TNQ}. \quad (7)$$

In this equation: *NumQMS* – number of queries with matching scores, *TNQ* – total *NumQMS*, *s* – the matching score threshold.

– **Combined Analysis:** By jointly assessing the CMC and CDF metrics, our evaluation provides a full overview of the proposed intelligent video surveillance system. The CMC curve offers insights into the system's ranking performance, while the CDF curve provides information on the distribution of matching scores. Together, these measures contribute to a thorough assessment of the system's capacity to accurately re-identify humans in real-world scenarios, incorporating both top-ranked matches and overall score distributions.

Our methodology directly addresses the difficulties indicated in the Introduction by leveraging the Market-1501 dataset to examine real-world performance. We utilize deep learning architectures, including VGG16 with triplet loss, and evaluate several distance measures to increase re-identification accuracy. The combination of CMC and CDF ensures a thorough performance evaluation, bridging existing information gaps and confirming our technique in the Results section.

3. Results and Discussion. In this chapter, we report the outcomes of our research on people re-identification approaches applying deep

learning algorithms. We investigate these data comprehensively, providing insights into the strengths and limitations of each technique. The results are presented utilizing figures, graphs, and tables for clarity and simplicity of understanding.

3.1. Key Findings and Interpretation. Table 2 summarizes the Rank-1, Rank-5, and Rank-10 accuracy rates for each technique. Figures 3 to 12 provide visual representations of the results through CMC and CDF curves.

Table 2. Rank-1, Rank-5, and Rank-10 accuracy rates for each technique

Technique	Rank-1	Rank-5	Rank-10
Euclidean	2%	5.5%	12.5%
Cosine	0.30%	4.73%	10.21%
Mahalanobis	2%	5.88%	11.56%
Siamese	0%	8%	12.5%
Triplet	0.06%	78.6%	93%

Figure 3(a) illustrates the CMC curve for Euclidean Distance, which shows a gradual increase in identification probability across different ranks but exhibits poor Rank-1 accuracy (2%). While the identification rate improves at Rank-5 (5.5%) and Rank-10 (12.5%), it remains ineffective for real-world person re-identification applications. Figure 3(b) illustrates the Cumulative Distribution Function (CDF) curve of Euclidean distances, highlighting the distribution of matching scores obtained from our experiments. Similarly, Figures 4(a) and Figure 5(a) depict the CMC curves for Cosine and Mahalanobis distances, respectively. The Cosine distance metric achieves the lowest Rank-1 accuracy (0.30%) and struggles to distinguish individuals effectively at lower ranks, showing limited Rank-5 (4.73%) and Rank-10 (10.21%) accuracy. The Mahalanobis distance metric slightly outperforms both Euclidean and Cosine, achieving 2% Rank-1 accuracy, but its performance remains moderate with 5.88% at Rank-5 and 11.56% at Rank-10. The corresponding CDF curves in Figures 4(b) and Figure 5(b) further confirm these trends, demonstrating slow convergence toward higher identification probabilities.

Rank-1 accuracy measures the percentage of queries where the correct match appears as the first result, reflecting immediate recognition accuracy. Rank-5 accuracy measures the percentage where the correct match is within the top five results, indicating performance with a small candidate set. These differ from traditional accuracy metrics, like precision,

which measure correct predictions out of all predictions without considering ranking.

In contrast, deep learning-based techniques show a notable improvement over traditional methods. Figure 6(a) presents the CMC curve for the Siamese network, which performs better than traditional distance metrics at higher ranks but fails at Rank-1 (0%). However, the method shows a significant improvement at Rank-5 (8%) and Rank-10 (12.5%), indicating better feature representation than distance-based metrics.

Figure 7(a) illustrates the CMC curve for the Triplet network, which outperforms all other techniques, achieving a Rank-1 accuracy of 0.06%. Despite this low Rank-1 accuracy, the Triplet network shows a dramatic increase at Rank-5 (78.6%) and Rank-10 (93%), demonstrating its superior ability to rank correct matches in higher ranks. The CDF curves in Figures 6 (b) and Figure 7 (b) reinforce these findings, highlighting the robustness of the Triplet network in learning discriminative embeddings for re-identification.

Figure 8 illustrates the average precision, recall, and F1-score for each technique, providing a broader evaluation beyond rank-based accuracy. The results highlight the Triplet network's superior performance across all ranking levels, confirming its ability to learn highly discriminative features and maximize correct match ranking at later ranks. In contrast, traditional distance metrics, as well as the Siamese network, exhibit significantly lower precision and recall, indicating their limited effectiveness in person re-identification tasks.

3.2. Comparison with Previous Studies. Our findings align with prior research emphasizing the superiority of deep metric learning approaches over traditional distance metrics. Compared to state-of-the-art results on Market-1501, studies such as [28] and [29] demonstrate that triplet loss significantly enhances person re-identification performance by optimizing the embedding space, particularly at higher rank levels (Rank-5 and Rank-10).

Our results confirm these observations, as the Triplet network achieves the highest accuracy at Rank-5 (78.6%) and Rank-10 (93%), demonstrating its effectiveness in ranking correct matches. However, the Triplet network shows weak Rank-1 accuracy (0.06%), suggesting that other deep learning approaches, such as Siamese networks, may still be useful at lower ranks.

Additionally, the study by [30] emphasizes that while deep learning methods significantly enhance identification accuracy, their effectiveness varies depending on model design and training strategy. In our case, the Triplet network demonstrates competitive performance at higher ranks

(Rank-5 and Rank-10), confirming its ability to learn meaningful embeddings for person re-identification. Although we utilized the VGG16 architecture – which is not the most recent development in CNN design – this choice was intentional to establish a clear and reproducible baseline. In future work, we plan to extend this framework by integrating more advanced backbones such as ResNet and EfficientNet, and subsequently applying transformer-based architectures to further enhance recognition performance.

Compared to traditional distance-based methods such as Euclidean, Cosine, and Mahalanobis metrics discussed in References [24, 25, 26], our approach demonstrates a significant improvement in Rank-5 and Rank-10 accuracy. However, compared to recent state-of-the-art deep learning methods listed in Table 1, our model offers competitive higher-rank performance but still lags in Rank-1 accuracy and overall end-to-end accuracy due to its reliance on an older backbone (VGG16).

3.3. Training Protocols. A summary of each technique’s strengths and limitations is provided in Table 3.

Table 3. Summary of strengths and limitations for each technique based on quantitative metrics

Technique	Strengths	Limitations
Euclidean	Simple to implement and computationally efficient	Low accuracy at Rank-1 (2%) and Rank-5 (5.5%), slightly better than Cosine
Cosine	Effective for high-dimensional data	Very low Rank-1 accuracy (0.3%), lower Rank-5 accuracy (4.73%) than Euclidean
Mahalanobis	Accounts for correlations in data	Low Rank-1 (2%) and Rank-5 (5.88%), similar to Euclidean but computationally heavier
Siamese	Outperforms Euclidean and Cosine at Rank-5 (8%)	No correct matches at Rank-1 (0%), modest improvement at Rank-10 (12.5%)
Triplet	Significantly better accuracy at Rank-5 (78.6%) and Rank-10 (93%)	Requires complex training, very low Rank-1 accuracy (0.06%)

One unexpected result in our analysis was that the Cosine distance metric exhibited a moderate improvement at Rank-10 compared to Rank-1 and Rank-5. Specifically, its accuracy increased from 0.30% (Rank-1) to 4.73% (Rank-5) and 10.21% (Rank-10). This suggests that while Cosine distance struggles with immediate identification, it retains some useful

feature representations that contribute to later-stage ranking improvements. However, since its overall accuracy remains lower than other methods, further investigation is needed to determine whether Cosine similarity can be effectively integrated with deep learning models to enhance ranking performance in re-identification tasks.

3.4. Impact of VGG16 Integration. Integrating VGG16 into the re-identification model significantly enhanced feature extraction by leveraging its deep hierarchical architecture. The convolutional layers of VGG16 captured fine-grained spatial details, improving the model's ability to distinguish individuals across different viewpoints, occlusions, and lighting conditions. As a result, deep learning-based techniques, particularly the Triplet network, achieved superior performance at Rank-5 (78.6%) and Rank-10 (93%), demonstrating their advantage over traditional distance metrics. However, the Triplet network exhibited low Rank-1 accuracy (0.06%), suggesting further improvements in early-stage recognition. Additionally, the increased computational complexity of VGG16 remains a challenge for real-time applications, highlighting the need for optimization techniques such as lighter architectures, model quantization, and feature distillation to balance accuracy and efficiency.

The integration of VGG16 for feature extraction follows the widely recognized approach by Simonyan and Zisserman (2014) [12], with our novel contribution lying in its application to the specific task of person re-identification, where we demonstrate its significant enhancement of identification accuracy compared to traditional methods.




Fig. 3. a) (CMC) Curve – Euclidean Distance; b) (CDF) Curve – Euclidean Distance




Fig. 4. a) (CMC) Curve Cosine Distance; b) (CDF) Curve Cosine Distance




Fig. 5. a) (CMC) Curve Mahalanobis Distance; b) (CDF) Curve Mahalanobis Distance




Fig. 6. a) CMC curve for Siamese networks; b) CDF curve for Siamese networks




Fig. 7. a) CMC curve for Triplet networks; b) CDF curve for Triplet networks

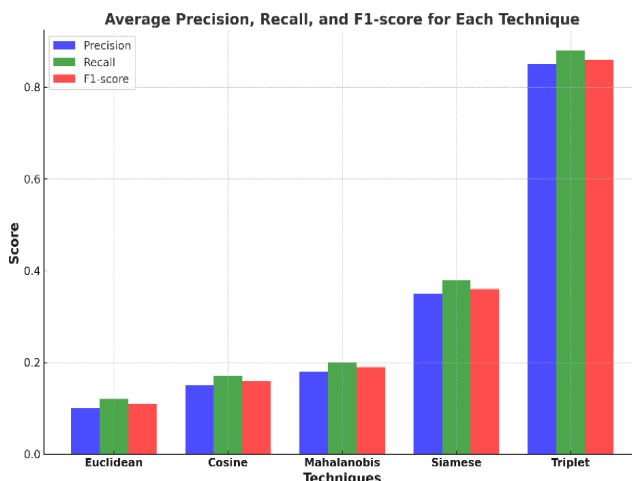


Fig. 8. Bar graph illustrating the average precision, recall, and F1-score for each technique

4. Conclusion and Future Directions. This paper provides a comparative analysis of traditional distance metrics and deep learning models for person re-identification, highlighting the advantages of deep metric learning approaches. Our findings demonstrate that while standard distance metrics such as Euclidean and Mahalanobis are computationally efficient, they suffer from significantly lower accuracy compared to deep learning-based techniques. The Triplet network, in particular, shows substantial gains at Rank-5 (78.6%) and Rank-10 (93%), making it highly effective for ranking-based retrieval tasks. However, its Rank-1 accuracy (0.06%) remains low, indicating limitations in immediate identification.

These results emphasize the importance of feature learning and embedding optimization in person re-identification. Deep learning models

capture complex patterns and variations in appearance, making them more robust than traditional methods. However, the increasing computational complexity of deep networks, particularly Triplet loss-based models, poses challenges for real-time deployment. This highlights the need for optimization techniques, such as lightweight architectures, quantization, and knowledge distillation, to balance accuracy and efficiency.

Beyond re-identification accuracy, our findings contribute to broader discussions on the scalability and applicability of deep learning for intelligent video surveillance. Future research should focus on:

- Constructing hybrid models that balance efficiency and accuracy.
- Integrating domain adaptation techniques to improve cross-dataset generalization.
- Studying privacy-preserving mechanisms (e.g., federated learning, differential privacy) for ethical surveillance applications.

Ultimately, this study reinforces the growing role of deep learning in person re-identification, providing valuable insights for researchers and practitioners to develop scalable, efficient, and ethical surveillance systems. The advancements in this field have far-reaching implications, from public security and law enforcement to smart city applications, where accurate and efficient identification is critical for real-world deployment.

References

1. Ezzahoutz A., Youssef H.M., Thami R.O.H. Detection evaluation and testing region incoming people's in a simple camera view. Second International Conference on the Innovative Computing Technology (INTECH 2012). Casablanca: IEEE, 2012. pp. 179–183. DOI: 10.1109/INTECH.2012.6457804.
2. Ezzahout A., Hadi Y., Thami R.O.H. Performance Evaluation of Mobile Person Detection and Area Entry Tests through a One-View Camera. Journal of Information. 2012. vol. 2. no. 3.
3. Sun Z., et al. A comprehensive review of pedestrian re-identification based on deep learning. Complex Intell. Syst. 2024. vol. 10. no. 2. pp. 1733–1768. DOI: 10.1007/s40747-023-01229-7.
4. Zahra A., Perwaiz N., Shahzad M., Fraz M.M. Person re-identification: A retrospective on domain specific open challenges and future trends. Pattern Recognition. 2023. vol. 142. p. 109669. DOI: 10.1016/j.patcog.2023.109669.
5. De Maesschalck R., Jouan-Rimbaud D., Massart D.L. The Mahalanobis distance. Chemometrics and Intelligent Laboratory Systems. 2000. vol. 50. no. 1. pp. 1–18. DOI: 10.1016/S0169-7439(99)00047-7.
6. Ghorbani H. Mahalanobis distance and its application for detecting multivariate outliers. Facta Universitatis, Series: Mathematics and Informatics. 2019. pp. 583–595. DOI: 10.22190/FUMI1903583G.
7. McLachlan G. Mahalanobis Distance. Resonance. 1999. vol. 4. pp. 20–26. DOI: 10.1007/BF02834632.

8. Tena S., Hartanto R., Ardiyanto I. Content-based image retrieval for fabric images: A survey. *Indones. J. Electr. Eng. Comput. Sci.* 2021. vol. 23. no. 3. DOI: 10.11591/ijeecs.v23.i3.pp1861-1872.
9. Samit Hatem A., Altememe M.S., Fadhel M.A. Identifying corn leaves diseases by extensive use of transfer learning: a comparative study. *Indones. J. Electr. Eng. Comput. Sci.* 2023. vol. 29. no. 2. DOI: 10.11591/ijeecs.v29.i2.pp1030-1038.
10. Gottipati S.B., Thumbur G. Multi-modal fusion deep transfer learning for accurate brain tumor classification using magnetic resonance imaging images. *Indones. J. Electr. Eng. Comput. Sci.* 2024. vol. 34. no. 2. DOI: 10.11591/ijeecs.v34.i2.pp825-834.
11. Sehree N.A., Khidhir A.M. Olive trees cases classification based on deep convolutional neural network from unmanned aerial vehicle imagery. *Indones. J. Electr. Eng. Comput. Sci.* 2022. vol. 27. no. 1. pp. 92–101. DOI: 10.11591/ijeecs.v27.i1.pp92-101.
12. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*. 2015. DOI: 10.48550/arXiv.1409.1556.
13. Aufar Y., Sitanggang I.S. Face recognition based on Siamese convolutional neural network using Kivy framework. *IJECS.* 2022. vol. 26. no. 2. pp. 764–772. DOI: 10.11591/ijeecs.v26.i2.
14. Xu J. A deep learning approach to building an intelligent video surveillance system. *Multimedia Tools and Applications.* 2021. vol. 80(4). pp. 5495–5515. DOI: 10.1007/s11042-020-09964-6.
15. Alami M.I., Ez-Zahout A., Omary F. Enhanced people re-identification in cctv surveillance using deep learning: a framework for real-world applications. *Informatics and Automation.* 2025. vol. 24. no. 2. pp. 583–603. DOI: 10.15622/ia.24.2.8.
16. Moghaddam A.S., Anvari F., Haghighi M.M., Fakhari M., Mohammadi M.R. IUST_PersonReId: A New Domain in Person Re-Identification Datasets. *arXiv preprint arXiv:2412.18874*. 2024. DOI: 10.48550/arXiv.2412.18874.
17. Wang G.A., Gong S., Cheng J., Hou Z. Faster Person Re-identification. *European conference on computer vision (ECCV 2020)*. Cham: Springer International Publishing, 2020. vol. 12353. pp. 275–292. DOI: 10.1007/978-3-030-58598-3_17.
18. Rami H., Ospici M., Lathuilière S. Online Unsupervised Domain Adaptation for Person Re-identification. *arXiv preprint arXiv:2205.04383*. 2022. DOI: 10.48550/arXiv.2205.04383.
19. Khan S.U., Khan N., Hussain T., Baik S.W. An intelligent correlation learning system for person Re-identification. *Engineering Applications of Artificial Intelligence.* 2024. vol. 128. DOI: 10.1016/j.engappai.2023.107213.
20. Khan S.U., Hussain T., Ullah A., Baik S.W. Deep-ReID: deep features and autoencoder assisted image patching strategy for person re-identification in smart cities surveillance. *Multimed Tools Appl.* 2024. vol. 83. no. 5. pp. 15079–15100. DOI: 10.1007/s11042-020-10145-8.
21. He S., Luo H., Wang P., Wang F., Li H., Jiang W. TransReID: Transformer-Based Object Re-Identification (CVPR). *Proceedings of the IEEE/CVF international conference on computer vision.* 2023. pp. 15013–15022.
22. Ye M., Chen S., Li C., Zheng W.-S., Crandall D., Du B. Transformer for Object Re-Identification: A Survey. *arXiv preprint arXiv:2401.06960*. 2024. DOI: 10.48550/arXiv.2401.06960.
23. Choudhary A., Mishra D., Karmakar A. Domain Adaptive Egocentric Person Re-identification. *Computer Vision and Image Processing: 5th International Conference (CVIP 2020)*. 2021. vol. 1378. pp. 81–92. DOI: 10.1007/978-981-16-1103-2_8.

24. Taye M.M. Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers*. 2023. vol. 12. no. 5. DOI: 10.3390/computers12050091.
25. Chopra S., Hadsell R., LeCun Y. Learning a Similarity Metric Discriminatively, with Application to Face Verification. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. San Diego, CA, USA: IEEE, 2005. vol. 1. pp. 539–546. DOI: 10.1109/CVPR.2005.202.
26. Schroff F., Kalenichenko D., Philbin J. FaceNet: A unified embedding for face recognition and clustering. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, MA, USA: IEEE, 2015. pp. 815–823. DOI: 10.1109/CVPR.2015.7298682.
27. Karanam S., Gou M., Wu Z., Rates-Borras A., Camps O., Radke R.J. A Systematic Evaluation and Benchmark for Person Re-Identification: Features, Metrics, and Datasets. *arXiv preprint arXiv:1605.09653*. 2018.
28. Xu P., Zhu X. DeepChange: A Long-Term Person Re-Identification Benchmark with Clothes Change. *IEEE/CVF International Conference on Computer Vision (ICCV)*. Paris, France: IEEE, 2023. pp. 11162–11171. DOI: 10.1109/ICCV51070.2023.01028.
29. Ye M., Shen J., Lin G., Xiang T., Shao L., Hoi S.C. Deep Learning for Person Re-identification: A Survey and Outlook. *arXiv preprint arXiv:2001.04193*. 2021. DOI: 10.48550/arXiv.2001.04193.
30. Ning E., Wang C., Zhang H., Ning X., Tiwari P. Occluded person re-identification with deep learning: A survey and perspectives. *Expert Systems with Applications*. 2024. vol. 239. DOI: 10.1016/j.eswa.2023.122419.

Idrissi Alami Mossaab — Ph.d. student, Department of computer science/faculty of sciences, Mohammed V University in Rabat. Research interests: big data engineering, information systems administration, computer engineering. The number of publications — 1. mossaab_idrissialami@um5.ac.ma; Av. des Nations Unies, 10000, Rabat, Morocco; office phone: +212(661)065-800.

Ez-zahout Abderrahmane — Professor of the department, Department of computer science/faculty of sciences, Mohammed V University in Rabat. Research interests: computer sciences, digital systems, big data, computer vision, intelligent systems. The number of publications — 30. a.ezzahout@um5r.ac.ma; Av. des Nations Unies, 10000, Rabat, Morocco; office phone: +212(669)455-252.

Omary Fouzia — Leader ipss team research, professor of the department, Department of computer science/faculty of sciences, Mohammed V University in Rabat. Research interests: cybersecurity, blockchain, cryptocurrency. The number of publications — 59. omary@fsr.ac.ma; Av. des Nations Unies, 10000, Rabat, Morocco; office phone: +212(661)391-420.

М. ИДРИССИ АЛАМИ, А. ЭЗ-ЗАХУТ, Ф. ОМАРИ
**СРАВНИТЕЛЬНОЕ ИССЛЕДОВАНИЕ МЕТОДОВ ПОВТОРНОЙ
ИДЕНТИФИКАЦИИ ЛИЧНОСТИ НА ОСНОВЕ МОДЕЛЕЙ
ГЛУБОКОГО ОБУЧЕНИЯ**

Идрисси Алами М., Эз-захут А., Омари Ф. Сравнительное исследование методов повторной идентификации личности на основе моделей глубокого обучения.

Аннотация. Повторная идентификация личности (Re-ID) имеет ключевую роль в системах интеллектуального видеонаблюдения, требуя точного распознавания людей с нескольких точек обзора камеры. Традиционные методы, основанные на метриках расстояния (евклидово и косинусное), сталкиваются с трудностями при обработке вариаций поз и случаев окклюзии, что ограничивает их эффективность. В данном исследовании рассматриваются модели глубокого метрического обучения, в частности сиамские и триплетные сети, для повышения точности повторной идентификации. Мы оцениваем эти методы на наборе данных Market-1501 с использованием кривых кумулятивной характеристики соответствия (CMC) и кумулятивной функции распределения (CDF). Результаты показывают, что триплетная сеть превосходит традиционные подходы на более высоких рангах, достигая точности 78,6% на Rank-5 и точности 93% на Rank-10, при этом демонстрируя низкую точность на Rank-1 (0,06%). Для сравнения, методы на основе евклидова и косинусного расстояний показывают низкую производительность на Rank-1 (2% и 0,30% соответственно), что подчеркивает их ограничения. Кроме того, включение архитектуры VGG16 улучшает извлечение признаков, повышая эффективность распознавания за счет улавливания мельчайших пространственных деталей. Данное сравнительное исследование показывает эффективность методов глубокого метрического обучения и подчеркивает его потенциал для практического применения в системах видеонаблюдения. Однако вычислительные требования глубоких сетей создают сложности для работы в реальном времени. Будущие исследования должны быть сосредоточены на оптимизации эффективности модели, снижении вычислительных затрат и тестировании в реальном времени.

Ключевые слова: метрики CMC/CDF, сверточные нейронные сети (CNN), глубокое обучение, повторная идентификация личности, VGG16, системы видеонаблюдения.

Литература

1. Ezzahoutz A., Youssef H.M., Thami R.O.H. Detection evaluation and testing region incoming people's in a simple camera view. Second International Conference on the Innovative Computing Technology (INTECH 2012). Casablanca: IEEE, 2012. pp. 179–183. DOI: 10.1109/INTECH.2012.6457804.
2. Ezzahout A., Hadi Y., Thami R.O.H. Performance Evaluation of Mobile Person Detection and Area Entry Tests through a One-View Camera. Journal of Information. 2012. vol. 2. no. 3.
3. Sun Z., et al. A comprehensive review of pedestrian re-identification based on deep learning. Complex Intell. Syst. 2024. vol. 10. no. 2. pp. 1733–1768. DOI: 10.1007/s40747-023-01229-7.
4. Zahra A., Perwaiz N., Shahzad M., Fraz M.M. Person re-identification: A retrospective on domain specific open challenges and future trends. Pattern Recognition. 2023. vol. 142. p. 109669. DOI: 10.1016/j.patcog.2023.109669.

5. De Maesschalck R., Jouan-Rimbaud D., Massart D.L. The Mahalanobis distance. *Chemometrics and Intelligent Laboratory Systems*. 2000. vol. 50. no. 1. pp. 1–18. DOI: 10.1016/S0169-7439(99)00047-7.
6. Ghorbani H. Mahalanobis distance and its application for detecting multivariate outliers. *Facta Universitatis, Series: Mathematics and Informatics*. 2019. pp. 583–595. DOI: 10.22190/FUMI1903583G.
7. McLachlan G. Mahalanobis Distance. *Resonance*. 1999. vol. 4. pp. 20–26. DOI: 10.1007/BF02834632.
8. Tena S., Hartanto R., Ardiyanto I. Content-based image retrieval for fabric images: A survey. *Indones. J. Electr. Eng. Comput. Sci.* 2021. vol. 23. no. 3. DOI: 10.11591/ijeecs.v23.i3.pp1861-1872.
9. Samit Hatem A., Altememe M.S., Fadhel M.A. Identifying corn leaves diseases by extensive use of transfer learning: a comparative study. *Indones. J. Electr. Eng. Comput. Sci.* 2023. vol. 29. no. 2. DOI: 10.11591/ijeecs.v29.i2.pp1030-1038.
10. Gottipati S.B., Thumbur G. Multi-modal fusion deep transfer learning for accurate brain tumor classification using magnetic resonance imaging images. *Indones. J. Electr. Eng. Comput. Sci.* 2024. vol. 34. no. 2. DOI: 10.11591/ijeecs.v34.i2.pp825-834.
11. Sehree N.A., Khidhir A.M. Olive trees cases classification based on deep convolutional neural network from unmanned aerial vehicle imagery. *Indones. J. Electr. Eng. Comput. Sci.* 2022. vol. 27. no. 1. pp. 92–101. DOI: 10.11591/ijeecs.v27.i1.pp92-101.
12. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*. 2015. DOI: 10.48550/arXiv.1409.1556.
13. Aufar Y., Sitanggang I.S. Face recognition based on Siamese convolutional neural network using Kivy framework. *IJECS*. 2022. vol. 26. no. 2. pp. 764–772. DOI: 10.11591/ijeecs.v26.i2.
14. Xu J. A deep learning approach to building an intelligent video surveillance system. *Multimedia Tools and Applications*. 2021. vol. 80(4). pp. 5495–5515. DOI: 10.1007/s11042-020-09964-6.
15. Alami M.I., Ez-Zahout A., Omary F. Enhanced people re-identification in cctv surveillance using deep learning: a framework for real-world applications. *Informatics and Automation*. 2025. vol. 24. no. 2. pp. 583–603. DOI: 10.15622/ia.24.2.8.
16. Moghaddam A.S., Anvari F., Haghighi M.M., Fakhari M., Mohammadi M.R. IUSTR_PersonReID: A New Domain in Person Re-Identification Datasets. *arXiv preprint arXiv:2412.18874*. 2024. DOI: 10.48550/arXiv.2412.18874.
17. Wang G.A., Gong S., Cheng J., Hou Z. Faster Person Re-identification. *European conference on computer vision (ECCV 2020)*. Cham: Springer International Publishing, 2020. vol. 12353. pp. 275–292. DOI: 10.1007/978-3-030-58598-3_17.
18. Rami H., Ospici M., Lathuilière S. Online Unsupervised Domain Adaptation for Person Re-identification. *arXiv preprint arXiv:2205.04383*. 2022. DOI: 10.48550/arXiv.2205.04383.
19. Khan S.U., Khan N., Hussain T., Baik S.W. An intelligent correlation learning system for person Re-identification. *Engineering Applications of Artificial Intelligence*. 2024. vol. 128. DOI: 10.1016/j.engappai.2023.107213.
20. Khan S.U., Hussain T., Ullah A., Baik S.W. Deep-ReID: deep features and autoencoder assisted image patching strategy for person re-identification in smart cities surveillance. *Multimed Tools Appl.* 2024. vol. 83. no. 5. pp. 15079–15100. DOI: 10.1007/s11042-020-10145-8.

21. He S., Luo H., Wang P., Wang F., Li H., Jiang W. TransReID: Transformer-Based Object Re-Identification (CVPR). Proceedings of the IEEE/CVF international conference on computer vision. 2023. pp. 15013–15022.
22. Ye M., Chen S., Li C., Zheng W.-S., Crandall D., Du B. Transformer for Object Re-Identification: A Survey. arXiv preprint arXiv:2401.06960. 2024. DOI: 10.48550/arXiv.2401.06960.
23. Choudhary A., Mishra D., Karmakar A. Domain Adaptive Egocentric Person Re-identification. Computer Vision and Image Processing: 5th International Conference (CVIP 2020). 2021. vol. 1378. pp. 81–92. DOI: 10.1007/978-981-16-1103-2_8.
24. Taye M.M. Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. Computers. 2023. vol. 12. no. 5. DOI: 10.3390/computers12050091.
25. Chopra S., Hadsell R., LeCun Y. Learning a Similarity Metric Discriminatively, with Application to Face Verification. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego, CA, USA: IEEE, 2005. vol. 1. pp. 539–546. DOI: 10.1109/CVPR.2005.202.
26. Schroff F., Kalenichenko D., Philbin J. FaceNet: A unified embedding for face recognition and clustering. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA: IEEE, 2015. pp. 815–823. DOI: 10.1109/CVPR.2015.7298682.
27. Karanam S., Gou M., Wu Z., Rates-Borras A., Camps O., Radke R.J. A Systematic Evaluation and Benchmark for Person Re-Identification: Features, Metrics, and Datasets. arXiv preprint arXiv:1605.09653. 2018.
28. Xu P., Zhu X. DeepChange: A Long-Term Person Re-Identification Benchmark with Clothes Change. IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France: IEEE, 2023. pp. 11162–11171. DOI: 10.1109/ICCV51070.2023.01028.
29. Ye M., Shen J., Lin G., Xiang T., Shao L., Hoi S.C. Deep Learning for Person Re-identification: A Survey and Outlook. arXiv preprint arXiv:2001.04193. 2021. DOI: 10.48550/arXiv.2001.04193.
30. Ning E., Wang C., Zhang H., Ning X., Tiwari P. Occluded person re-identification with deep learning: A survey and perspectives. Expert Systems with Applications. 2024. vol. 239. DOI: 10.1016/j.eswa.2023.122419.

Идрисси Алами Моссааб — аспирант, кафедра компьютерных наук/факультет естественных наук, Университет Мохаммеда V в Рабате. Область научных интересов: инженерия больших данных, администрирование информационных систем, компьютерная инженерия. Число научных публикаций — 1. mossaab_idrissialami@um5.ac.ma; проспект Объединенных Наций, 10000, Рабат, Марокко; p.t.: +212(661)065-800.

Эз-захут Абдеррахман — профессор кафедры, кафедра компьютерных наук/факультет естественных наук, Университет Мохаммеда V в Рабате. Область научных интересов: компьютерные науки, цифровые системы, большие данные, компьютерное зрение, интеллектуальные системы. Число научных публикаций — 30. a.ezzahout@um5r.ac.ma; проспект Объединенных Наций, 10000, Рабат, Марокко; p.t.: +212(669)455-252.

Омари Фузия — руководитель исследовательской группы IPSS, профессор кафедры, кафедра компьютерных наук/факультет естественных наук, Университет Мохаммеда V в Рабате. Область научных интересов: кибербезопасность, блокчейн, криптовалюта. Число научных публикаций — 59. omary@fsr.ac.ma; проспект Объединенных Наций, 10000, Рабат, Марокко; p.t.: +212(661)391-420.

Руководство для авторов

Взаимодействие автора с редакцией осуществляется через личный кабинет на сайте журнала «Информатика и автоматизация» <http://ia.spcras.ru/>. При регистрации авторам рекомендуется заполнить все предложенные поля данных. Подготовка статьи ведется с помощью текстовых редакторов MS Word 2007 и выше или LaTeX. Объем основного текста (до раздела Литература) - от 20 до 30 страниц включительно. Переносы запрещены. Номера страниц не проставляются. Основная часть текста статьи разбивается на разделы, среди которых являются обязательными: введение, хотя бы один «содержательный» раздел и заключение. Допускается также мотивированное содержанием и структурой материал а выделение подразделов. В основную часть опускается помещать рисунки, таблицы, листинги и формулы. Правила их оформления подробно рассмотрены на нашем сайте в разделе «Руководство для авторов».

Author guidelines

Interaction between each potential author and the Editorial board is realized through the personal account on the website of the journal "Informatics and Automation" <http://ia.spcras.ru/>. At the registration the authors are requested to fill out all data fields in the proposed form. The submissions should be prepared using MS Word 2007, LaTeX. The text of the paper in the main part should not exceed 30 pages. Pages are not numbered; hyphenations are not allowed. Certain figures, tables, listings and formulas are allowed in the main section, and their typography is considered in more detail at the journal web.

Signed to print 23.06.2025. Passed for print 25.06.2025.

Printed in Publishing center GUAP.

Address: 67 litera A, B. Morskaya, St. Petersburg, 190000, Russia

Founder and Publisher: SPC RAS.

Address: 39 litera A, 14th Line V.O., St.Peterburg, 199178, Russia.

The journal is registered in the Federal Service for Supervision of Communications,
Information Technology, and Mass Media,

Registration Certificate (registration number) ПИ № ФС77-79228 dated September 25, 2020

Subscription Index П5513, Russian Post Catalog

Подписано к печати 23.06.2025. Дата выхода в свет 25.06.2025.

Формат 60х90 1/16. Усл. печ. л. 16,9. Заказ № 207. Тираж 300 экз., цена свободная.

Отпечатано в Редакционно-издательском центре ГУАП.

Адрес типографии: Б. Морская, д. 67, лит. А, г. Санкт-Петербург, 190000, Россия

Учредитель и издатель: СПб ФИЦ РАН.

Адрес учредителя и издателя: 14-я линия В.О., д. 39, лит. А, г. Санкт-Петербург, 199178, Россия

Журнал зарегистрирован Федеральной службой по надзору в сфере связи,
информационных технологий и массовых коммуникаций,
свидетельство о регистрации (регистрационный номер) ПИ № ФС77-79228 от 25 сентября 2020 г.

Подписной индекс П5513 по каталогу «Почта России»