

**СИСТЕМНЫЙ АНАЛИЗ
И ПРИКЛАДНАЯ
ИНФОРМАТИКА**

№ 2, 2026

**SYSTEM ANALYSIS
AND APPLIED
INFORMATION SCIENCE**

№ 2, 2026



**Международный
научно-технический журнал**
Издается с декабря 2012 года

**International
Science and Technical Journal**
Published since December, 2012

Учредитель

Белорусский национальный
технический университет

Founder

Belarusian National
Technical University

Главный редактор

Дробыш Алексей Анатольевич

Editor-in-chief

A. A. Drobysh

Редакционная коллегия

Д. В. Капский (зам. главного редактора),
А. А. Большаков (РФ), В. А. Вишняков,
Л. С. Герасимович, А. В. Гулай,
Н. Н. Гурский, О. О. Зарипов (Узбекистан),
А. А. Лобатый, С. А. Ляпин (РФ),
В. А. Малкин, А. В. Малолетов (РФ),
И. А. Сатиков (ответственный секретарь),
В. В. Старовойтов, В. А. Федоров (РФ),
С. В. Харитончик, Чень Дунъюэ (Китай),
Янг Янг (Китай), Ю. Ф. Яцына

Editorial board

D. Kapski (deputy editor-in-chief),
A. Bolshakov (RF), V. Vishnyakov,
L. Gerasimovich, A. Gulaj,
N. Gursky, O. Zaripov (Uzbekistan),
A. Lobaty, S. Lyapin (RF),
V. Malkin, A. Maloletov (RF),
I. Satikov (executive secretary),
V. Starovoitov, V. Fedorov (RF),
S. Haritonchik, Chen Dongyue (Kitaj),
Yang Yang (Kitaj), U. Yatsyna

Журнал включен в “Перечень научных изданий Республики Беларусь
для опубликования результатов диссертационных исследований”

Журнал включен в международные каталоги и базы данных:

- | | |
|------------------|---------------|
| ❖ РИНЦ | ❖ EBSCO |
| ❖ ЭБС «Лань» | ❖ BASE Search |
| ❖ DOAJ | ❖ OpenAIRE |
| ❖ Google Scholar | ❖ WorldCat |
| ❖ Cyberleninka | ❖ ROAR |

Ведущий научный редактор

И. А. Сатиков

Executive secretary of the editorial board

I. Satikov

Технический редактор

З. А. Парфенчик

Technical Editor

Z. Parfenchik

Адрес редакции

пр. Независимости, 65, Минск, 220013,
Республика Беларусь
Тел. +375 17 227-69-17
e-mail: ca_pi@bntu.by

Editorial board address

Nezavisimosty Ave., 65, Minsk, 220013,
Republic of Belarus
Tel. +375 17 227-69-17
e-mail: ca_pi@bntu.by

Свидетельство о государственной регистрации средства массовой информации
№1540 от 08.06.2012, выданное Министерством информации Республики Беларусь.
Подписано в печать 00.00.2026. Дата выхода в свет ????. Формат бумаги 60x84 1/8. Бумага мелованная.

Цифровая печать. Усл. печ. л. 10,2. Уч.-изд. л. 9,1. Тираж 62 экз. Заказ 0000.

Отпечатано в БНТУ. ЛП № 38200000006896 от 03.03.2014.

220013, г. Минск, пр. Независимости, 65.

СОДЕРЖАНИЕ

СИСТЕМНЫЙ АНАЛИЗ

Спринджук М. В., Кукарцев В. В., Ноздрачева А. В., Кончиц А. П., Владыко А. С., Берник В. И., Сукач Е. И.
Оценочные функции моделей молекулярного докинга белков: классификация и применение в биоинформатике.....4

Голда О.
Системно-динамический подход к моделированию организационной модели управления производством промышленного предприятия.....15

Русина Н. В.
Интеграция системного подхода к решению проблем процесса сушки зерна.....23

УПРАВЛЕНИЕ ТЕХНИЧЕСКИМИ ОБЪЕКТАМИ

Капский Д. В., Коржова А. В.
Методология формирования динамических моделей мониторинга атмосферного воздуха в урбанизированных зонах на основе алгоритмов оптимизации транспортных сенсорных сетей.....28

Лобатый А. А., Семак Ю. И., Готина Л. Н.
Система поддержки принятия решений при автоматизированном управлении.....38

ОБРАБОТКА ИНФОРМАЦИИ И ПРИНЯТИЕ РЕШЕНИЙ

Ефремов А. А., Го Юй
Принятие инвестиционных решений на рынке криптовалют с использованием модели Марковица и предобученных нейронных сетей.....46

Заерко Д. В., Боброва Н. Л., Заерко Дм. В.
Оценка тоновой девиации граничных пикселей статического растрового изображения с использованием алгоритма сбалансированного «доопределения».....54

Голуб Ю. И., Лукашевич М. М., Старовойтов В. В.
Прототип системы удаленного автоматизированного скрининга диабетической ретинопатии.....60

Вишняков В. А.
Мобильная система с цифровым двойником для диагностики и поддержки терапии пациентов с неврологическими заболеваниями.....70

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

Гуляев В. О., Захарова О. И.
Эволюция архитектур трансформеров: от самовнимания к эффективным sparse-моделям.....78

CONTENT

SYSTEM ANALYSIS

Sprindzuk M. V., Kukartsev V. V., Nozdracheva A. V., Konchits A. P., Vladyko A. S., Bernik V. I., Sukach E. I.
Scoring Functions of Molecular Protein Docking Models: Classification and Application in Bioinformatics.....4

Golda O.
A System Dynamics Approach to Modeling the Organizational Model of Production Management at an Industrial Enterprise.....15

Rusina N. V.
Integration of a Systemic Approach to Solving Problems of the Grain Drying Process.....23

MANAGEMENT OF TECHNICAL OBJECTS

Kapski D. V., Korzhova A. V.
Methodology of Forming Dynamic Air Quality Monitoring Models in Urban Areas Based on Traffic Sensor Network Optimization Algorithms.....28

Lobaty A. A., Semak Y. I., Gotina L. N.
Decision Support System for Automated Control.....38

DATA PROCESSING AND DECISION-MAKING

Efremov A. A., Guo Yu
Making Investment Decisions in the Cryptocurrency Market Using the Markowitz Model and Pre-Trained Neural Networks.....46

Zaerko D. V., Bobrova N. L., Zaerko Dm. V.
Tone Deviation Evaluation of Boundary Pixels Static Raster Image Using Balanced Extending Algorithms.....54

Golub Y. I., Lukashevich M. M., Starovoitov V. V.
Prototype of a Remote Automated Screening System for Diabetic Retinopathy.....60

Vishniakou U. A.
Mobile System with a Digital Twin for the Diagnosis and Support of Therapy of Patients with Neurological Diseases.....70

INFORMATION TECHNOLOGIES

Gulyaev V. O., Zakharova O. I.
Evolution of Transformer Architectures: from Self-Attention to Efficient Sparse Models.....78

СИСТЕМНЫЙ АНАЛИЗ

SYSTEM ANALYSIS

М. В. СПРИНДЖУК ¹⁾, В. В. КУКАРЦЕВ ^{2,3)}, А. В. НОЗДРАЧЕВА ⁴⁾, А. П. КОНЧИЦ ⁵⁾, А. С. ВЛАДЫКО ⁶⁾,
В. И. БЕРНИК ⁷⁾, Е. И. СУКАЧ ⁸⁾

ОЦЕНОЧНЫЕ ФУНКЦИИ МОДЕЛЕЙ МОЛЕКУЛЯРНОГО ДОКИНГА БЕЛКОВ: КЛАССИФИКАЦИЯ И ПРИМЕНЕНИЕ В БИОИНФОРМАТИКЕ

¹⁾ Объединенный институт проблем информатики Национальной академии наук Беларуси
г. Минск, Республика Беларусь

²⁾ Российский государственный аграрный университет — МСХА им. К. А. Тимирязева
г. Москва, Российская Федерация

³⁾ Московский государственный технический университет им. Н. Э. Баумана
г. Москва, Российская Федерация

⁴⁾ Национальный исследовательский центр эпидемиологии и микробиологии имени почетного академика
Н. Ф. Гамалеи Минздрава России, г. Москва

⁵⁾ Институт леса Национальной академии наук Беларуси
г. Гомель, Республика Беларусь

⁶⁾ Научно-исследовательский институт гигиены, токсикологии, эпидемиологии, вирусологии и микробиологии
государственного учреждения «Республиканский центр гигиены, эпидемиологии и общественного здоровья»
г. Минск, Республика Беларусь

⁷⁾ Институт математики Национальной академии наук Беларуси
г. Минск, Республика Беларусь

⁸⁾ Гомельский государственный университет имени Франциска Скорины
г. Гомель, Республика Беларусь

Аннотация. В обзорной статье представлена обобщенная интегрированная классификация оценочных (скоринговых функций) молекулярного докинга моделей взаимодействия белков. Приводится описание различных видов таких оценочных функций, рассматриваются отдельные релевантные вопросы биофармацевтики, медицинской кибернетики, вычислительной биологии и биофизики, прикладной математики. Статья может быть интересна широкому кругу читателей, в том числе для ученых различных специальностей, инженеров-программистов, разрабатывающих автоматизированные системы обработки биоинформации, для преподавателей-лекторов по данной тематике, для магистрантов и аспирантов по специальностям биоинформатики, системного анализа, системы медицинского назначения и теоретических основ информатики.

Ключевые слова: молекулярный докинг, медицинская кибернетика, вычислительная биология, геномика, распознавание образов, искусственный интеллект, биоинформатика, вычислительный анализ, прикладная математика, компьютерные системы медицинского назначения, приборостроение и метрология

Введение, актуальность и терминология

Компьютерные методы, применяемые для разработки, перепрофилирования [1–4], исследования новых лекарственных средств, подразделяются на методы изучения лигандов и на так называемые структурные (рис. 1–3). Методы, основанные на исследовании лиганд, требуют объекта активных лигандов и используют модели количественной зависимости структура-активность (QSAR, Quantitative structure–activity relationship), фармакофор (в широком смысле слова это ансамбль характеристик целевых структур, взаимодействие которых подвергается изучению и анализу) и химическое сходство для прогнозирования новых соединений. Структурные методы требуют трехмерной структуры рецептора и лигандов, а открытие новых активных соединений основано на определении физических взаимодействий между рецептором и небольшими молекулами с образованием биологически активного комплекса [5–7].



Рисунок 1. Сферы применения технологий искусственного интеллекта в биофармацевтике



Рисунок 2. Области применения технологий искусственного интеллекта для изучения структурной биоинформатики протеинов




Рисунок 3. Организация сфер исследования биоинформатики белковых комплексов

Одной из областей применения моделей молекулярного докинга взаимодействия белков является тема изучения устойчивости микробов к антибиотикам. Такая резистентность микроорганизмов представляет собой серьезную угрозу для общественного здравоохранения. Ассоциируемые с этим феноменом высокие показатели заболеваемости и смертности главным образом имеют причины неправильного назначения антибиотиков и широко распространенного бесконтрольного использования антибиотиков. Поэтому поиск стратегий борьбы с лекарственной устойчивостью имеет важное значение и высокую актуальность сегодня. Информационные технологии активно применяются для вышеуказанной медицинской проблемы.

Программное обеспечение молекулярного докинга (МД) основано на двух основных компонентах: алгоритме конформационного поиска и оценочной функции (ОФ) (рис. 4, 5) [8].

Сравнивать программное обеспечение для докинга достаточно проблемно, так как сайты связывания и процессы распознавания имеют уникальные особенности, которые в конечном итоге делают взаимодействия белок-лиганд специфичными, что может потребовать индивидуального анализа (для конкретных мишеней или связанных рецепторов).

Молекулярный докинг (МД) [9] и виртуальный скрининг (ВС) [10–12] – это современные эффективные инструменты для выявления новых кандидатов в лекарственные препараты, обладающих антагонисти-

ческой активностью в отношении ферментов или белковых рецепторов, имеющих медицинское и биологическое значение. Докинг прогнозирует и ранжирует конформации лиганда для конкретной мишени [8].



Рисунок 4. Разработанная, интегрированная современная классификация оценочных функций моделей молекулярного докинга, расширено с использованием источника [13]



Рисунок 5. Компоненты характеристики эффективности оценочных функций моделей молекулярного докинга [14].

Оценочные функции (рис. 4, 5) представляют собой вычислительные методы, широко применяемые при разработке структурно-ориентированных лекарств для оценки взаимодействий белок-лиганд. Большой набор оценочных (скоринговых) функций был опубликован с начала 1990-х годов [15]. Возможность подсчета баллов является основным элементом виртуального скрининга [16]. Докинг белков с белками является ключом к пониманию того, как белки работают вместе. Алгоритмы вычислительного докинга предсказывают трехмерную структуру комплекса, используя данные о трехмерных структурах отдельных белков.

Подсчет очков проводится для выявления конформаций, сходных с нативной структурой. Хорошая ОФ должна правильно и эффективно оценивать модели, близкие к нативным, и присваивать низкие оценки к ненативным конформациям. Задача на подсчет очков определяется в конкурсе под названием CAPRI (Critical Assessment of Prognostic Interaction, критическая оценка прогнозирования взаимодействий) [17]. Надежность молекулярного докинга зависит от точности применяемых ОФ, которые могут направлять и

определять положения лигандов, когда их генерируются тысячи. ОФ может использоваться для определения режима связывания и точного местоположения лиганда, прогнозирования аффинности (меры прочности) связывания и идентификации потенциальных лекарственных средств для заданной белковой мишени. Таким образом, как наиболее важный компонент молекулярного докинга, ОФ имеют три доминирующие функции: первая – определение способа связывания и места связывания лиганда с белком; второй – предсказание абсолютного сродства связывания между белком и лигандом при оптимизации отведения; третья – виртуальный скрининг, который может идентифицировать потенциальные лекарственные средства для данного комплекса белка-мишени путем поиска в большой базе данных лигандов [18].

Метрики сравнительного анализа и характеристик оценочных функций

Стандартные бенчмарки (проверенные стандартные эталоны) имеют решающее значение для объективного изучения и характеристики ОФ (рис. 5), обеспечивая воспроизводимый и надежный способ сравнения различных методов. PDBbind [19], DUD-E[20], DEKOIS 2.0 [19] являются примерами широко используемых бенчмарков для анализа функций ОФ. Для количественной оценки эффективности ОФ учитываются эффективность прогнозирования позиций конформации, классификации «активный/неактивный» и прогнозирования сродства. ОФ обычно сами оцениваются по четырем аспектам, связанным с тремя вышеупомянутыми целями ОФ.

Сила докинга: способность ОФ определять нативный режим связывания как наиболее правильное ранжированное решение. Среднеквадратичное отклонение (СКО) является наиболее часто используемой метрикой для характеристики эффективности ОФ. Скрининговая сила: способность ОФ правильно отличать активные соединения от неактивных молекул. Тест скрининговой силы не требует, чтобы скоринговая функция правильно предсказывала абсолютную аффинность связывания. Скрининговая сила обычно количественно оценивается с помощью *больцмановского* усиления дискриминации рабочих характеристик приёмника и фактора обогащения.

Ранжирующая мощность: способность ОФ правильно ранжировать соединения в соответствии с их аффинностями связывания с одним и тем же целевым белком. Коэффициент корреляции Спирмена и τ у Кендалла – метрики, широко используемые для оценки ранжирующей мощности ОФ.

Прогностическая эффективность ОФ может различаться в разных экспериментах по бенчмаркингу из-за таких факторов, как: состав набора данных, структурное качество белок-лиганд комплексов, уровень опыта исследователей, проводящих эксперименты, и детали протокола вычислений [14].

Поскольку в большинстве исследований бенчмаркинга оценочные функции оцениваются на нескольких сотнях комплексов, небольшие различия в коэффициенте корреляции Спирмена, например, между 0,05 и 0,15, не имеют явной статистической значимости. Таким образом, для надежного сравнения методологий стыковки и оценочных функций требуются более крупные бенчмаркинговые наборы, состоящие из высококачественных структур комплексов белок-лиганд [14].

Физические оценочные функции

Физические ОФ имеют в основе алгоритмы на основе вычислений моделей силовых полей и квантовой механики. Классическая ОФ на основе силового поля вычисляет энергию связи путем накопления ван-дер-ваальсовского и электростатического взаимодействия между парами атомов белок-лиганд, который учитывает вклад энтальпии (это сумма внутренней энергии термодинамической системы и произведения ее давления и объема) в энергию. Поскольку он пренебрегает энтропией (это научная концепция, которая чаще всего ассоциируется с состоянием беспорядка, случайности или неопределенности) и эффектом растворителя, производительность ОФ на основе силового поля недостаточно хороша. Таким образом, ОФ на основе силового поля улучшается за счет включения торсионной энтропии лигандов и эффекта сольватации/десольватации (в водном растворе это гидратация/дегидратация), описываемого явными и неявными моделями растворителя [18].

Оценочные функции, основанные на знаниях

Оценочные функции, основанные на знаниях, получают желаемые парные потенциалы из трехмерных структур большого набора комплексов белок-лиганд, используя обратный статистический принцип Больцмана. Предполагается, что частота различных пар атомов на разных расстояниях связана с взаимодействием двух атомов и преобразует частоту в зависящий от расстояния потенциал средней силы. Самым большим преимуществом применения ОФ, основанных на знаниях, является снижение стоимости вычислений и повышение точности прогнозирования по сравнению с физическими и эмпирическими ОФ [18].

Однако ОФ, основанным на знаниях, проблематично найти эталонное состояние. В настоящее время существуют две классические стратегии определения эталонного состояния. Одна из них – аппроксимация эталонного состояния случайным распределением пар атомов в наборе обучающих данных; другая представляет элемент коррекций, основанный на первой стратегии для повышения точности и достоверности ОФ, основанной на знаниях, такой как алгоритм коррекции объемного коэффициента, основанный на физических процессах и явлениях итеративный вычислительный метод.

Эмпирические оценочные функции

Эмпирические ОФ [21–27] отражают сродство связывания комплекса путем суммирования основных энергетических факторов для связывания белок-лиганд, таких как водородные связи, гидрофобные эффекты, стерические столкновения и т. д. Обычно используется обучающий набор с известными сродствами связывания для оптимизации весов энергетических факторов для эмпирических ОФ с помощью линейного регрессионного анализа. Эмпирические ОФ изучаются по двум основным направлениям исследований. Одно из направлений – как применить большой и высококачественный набор обучающих данных для оптимизации белок-лигандных структур; другое направление – как выбрать подходящие энергетические условия с помощью пошаговых переменных и систематического отбора в отношении целевого белка. В настоящее время эмпирические ОФ обычно реализуются в программных системах докинга белков и лигандов. Хотя эмпирические ОФ разлагают сродство связывания белок-лиганд на несколько отдельных энергетических характеристик, подобно ОФ, основанному на физических процессах, как правило, они используют гибкую и интуитивную функциональную форму, отличную от использования устоявшихся моделей, которые имеют ОФ, основанные на таких физических вычислениях. Эти ОФ эффективны для прогнозирования сродства связывания, положения лиганда и виртуального скрининга с низкими вычислительными затратами, однако они плохо подходят для описания взаимосвязей между сродством связывания и кристаллоидными элементами и сталкиваются с проблемами двойного счета.

Оценочные функции на основе машинного обучения

В отличие от классических ОФ с предполагаемой математической функциональной формой, ОФ на основе машинного обучения [28–31] используют различные вычислительные методы машинного обучения, такие как машины опорных векторов, случайные леса, регрессии, дискриминантные модели, бустинг и пакетирование, кластеризация и различные нейронные сети, включая сложные архитектуры глубокого обучения. Хотя, согласно данным современной научной литературы, ОФ на основе машинного обучения превосходили классические ОФ, они довольно редко напрямую включаются в программное обеспечение для докинга, но обычно используются для повторной его оценки. Причина такого решения заключается в том, что ОФ на основе машинного обучения зависят от наборов обучающих данных. Если белок и лиганд в моделировании стыкуются с помощью классического программного обеспечения для докинга, а затем стыкованная структура анализируется с помощью ОФ машинного обучения, возможно, что точность докинга будет значительно улучшена.

Глубокое обучение

По сравнению с функциями оценки, описанными выше, функция оценки глубокого обучения способна извлекать признаки вместе с процессом подбора параметров модели к доступным данным. Модель сверточной нейронной сети – одна из популярных моделей глубокого обучения для ОФ. Эту модель можно применять для классификации связывания лекарственных средств и прогнозирования аффинности прямого связывания. В настоящее время продемонстрировано, что модель сверточной нейронной сети более эффективна, чем классические методы машинного обучения, хотя она становится чрезвычайно трудоемкой по мере увеличения узлов и глубины сети. Более того, поскольку глубокие нейронные сети сильны в разработке многозадачных классификаторов или регрессоров, они могут прогнозировать сродство связывания белка с лигандом и исследовать активные лиганды из неактивных. Как глубокое обучение, так и основанные на физике, эмпирические и основанные на знаниях ОФ обычно используются в ряде опубликованных исследований. Эти ОФ были успешно включены в популярное программное обеспечение для докинга, такое как DOCK, SYBYL, Discovery Studio, Schrodinger, Autodock, AutodockVina (преимущественно основанные на физике ОФ) и многие другие. Однако, поскольку у каждого ОФ есть очевидные недостатки, программное обеспечение для докинга не может работать идеально во всех аспектах. ОФ, основанные на физических процессах, являются мощными инструментами прогнозирования свободной энергии, однако работают достаточно медленно.

Обзоры литературы и опросы показывают, что методы глубокого обучения показали себя значительно лучше классических методов для шести наборов данных, а именно CAPRI Scoreset v2022 (как сложных, так и простых комплексов), BM4, Dockground, PDB-2023 и MaSIF-test. Программный инструмент PIsToN показал самое высокое значение AUC (площадь под кривой) для четырех из шести наборов данных, в то время как GNN-DOVE превзошел своих конкурентов для Dockground. Почти для всех наборов данных методы, основанные на глубоком обучении, превосходили конкурирующие классические методы. Для наборов данных CAPRI Score Refined, BM4 и PDB-2023 у PIsToN было наибольшее количество результатов в верхних рейтингах для прогнозов top 1, top 10, top 25, top 100 и top 200, за исключением одного значения, когда HADDOCK [20] показал себя лучше других методов с 94 % попаданий для прогнозов top 25 только с набором данных BM4. Однако PIsToN отстает от своего конкурента dMaSIF с точки зрения измерения времени выполнения из-за этапа предварительной обработки. PIsToN предварительно вычисляет характеристики сетки поверхности двух белков, участвующих в создании комплекса, чтобы зафиксировать топологические взаимосвязи и геометрию их поверхностей.

Гибридные мультикомпонентные оценочные функции

Учитывая, что классические оценочные функции имеют свои преимущества и ограничения, для повышения точности ОФ обычно используется объединение различных функций оценки (**гибридные консенсусные ОФ**). Примерами гибридных ОФ являются MultiScore, GFscore [32], SeleX-CS [33], VoteDock [34]. Гибридные ОФ объединяют различные индивидуальные оценки с помощью стратегий консенсуса, таких как голосование по числу, число по числу, ранг по числу, средний ранг, линейная комбинация и т. д. Гибридные ОФ, вероятно, будут работать лучше, чем автономные единичные ОФ. Причина может заключаться в том, что объединение разнородных типов оценочных функций может компенсировать недостатки каждого из них. Однако такие функции подсчета баллов, очевидно, требуют больше времени. По этой причине исследования функций оценки на основе машинного обучения стали в настоящее время актуальной областью исследований. Точность прогнозирования для ОФ, основанных на машинном обучении, можно повысить, увеличив набор обучающих данных. Поскольку из академических и промышленных областей будет поступать все больше структурных и интерактивных данных, мы считаем, что ОФ машинного обучения имеют потенциал доминировать над ОФ будущего. PIsToN (Protein Interfaces with Transformer Network – протеиновые интерфейсы с трансформаторной сетью) является одним из самых успешных с точки зрения точности и эффективности и новейшим среди современных инструментов на основе глубокого обучения. PIsToN вырезает и изолирует пары участков из интерфейса, по одному для каждого взаимодействующего белка. Затем информация с каждого участка преобразуется в многоканальные изображения, где каждый канал представляет одну из характеристик взаимодействия, включая относительную доступную площадь поверхности, кривизну, заряд, электростатику и гидрофобность. Использование модуля, называемого ViT (Vision Transformer), отличает его от других методов. Встраивание, произведенное ViT, затем объединяется с «гибридными» эмпирическими энергетическими терминами, включая Ван-дер-Ваальса, электростатику и десольватацию, что позволяет ему изучать характеристики сложных энергий связи.

Наконец, модель множественного внимания группирует энергетические характеристики и свойства интерфейса в несколько групп, каждая из которых содержит независимую сеть трансформаторов. Эти независимые сети объединяются в преобразователь-кодер для оценки комплексов как собственных или не собственных ложных сигналов.

Графовые нейронные сети – это новый метод обработки данных, представляющий собой набор архитектур глубокого обучения для работы с данными, которые можно представить в виде графа. Подавляющее большинство графовых нейронных сетей делятся

на три категории (сверточные, внимания и передачи сообщений).

Граф (V, E) состоит из набора вершин $v_i \in V$ и набора ребер $e_{ij} \in E$, соединяющих вершины. Характеристики x связаны с вершинами (и, необязательно, ребрами), и такие характеристики впоследствии обновляются следующим образом [35]:

$$h_u = \phi\left(x_u, \bigoplus_{v \in \mathcal{N}_u} \psi(x_u, x_v)\right), \quad (1)$$

где ϕ и ψ – обучаемые функции (часто обучаемые аффинные преобразования с функциями активации), где $\bigoplus$ представляет собой инвариантную к перестановкам функцию, позволяющую агрегировать признаки, такие как сумма, среднее значение и максимум по соседству $\mathcal{N}_u$ узла u . ψ – функция передачи сообщений (которая может быть обобщена для включения также признаков ребер), в то время как ϕ – функция обновления вершин. Также можно изучать признаки ребер, введя скрытое представление h_{uv} для ребер [35].

Поскольку молекулы можно естественным образом представить в виде графов, где узлы графов представляют различные атомы, а ребра графа представляют химические связи между такими атомами, графовые нейронные сети хорошо подходят для применения в области химии [35].

Консенсусная оценка и переоценка

Хорошо известно, что каждая функция оценки имеет свои сильные и слабые стороны. Способом улучшения результатов сверх уровня, который может быть получен с помощью одной оценочной функции, является использование методологии, называемой консенсусной оценкой.

Оценочные функции так называемого консенсуса объединяют различные ОФ, присваивая различные веса вкладу различных альтернатив, чтобы улучшить различение активных и неактивных элементов в виртуальном скрининге. Несколько исследований продемонстрировали, что применение ОФ консенсуса может уменьшить количество ложноположительных и ложноотрицательных результатов, а также виртуального скрининга.

В ходе так называемой повторной оценки позиций (конформации), сгенерированные программой докинга, оцениваются с целью поиска благоприятных конформаций и ранжируются для выбора наиболее удачных совпадений. Однако расчет сродства связывания является неопределенным из-за внутренних проблем, связанных с упрощенными условиями оценки. Одним из способов решения этой проблемы является использование более строгих энергетических расчетов после процесса докинга, хотя это ограничено чрезмерными вычислительными затратами для больших химических библиотек. Таким образом, результаты, полученные после докинга, можно переоце-

нить и/или отфильтровать с использованием различных функций оценки, которые оценивают различные характеристики.

Программное обеспечение XScore и DSX обычно используется для переоценки моделей молекулярного докинга: XScore вычисляет сродство связывания заданных молекул лиганда, связанных с целевым белком, с помощью эмпирической функции, которая включает взаимодействия Ван-дер-Ваальса, водородные связи, а также гидрофобные и деформационные члены. DSX – компьютерная программа, имеющая ОФ, основанную на знаниях, позволяющая оценивать интересующие комплексы белок-лиганд и визуализировать вклады оценок на атом, что является интуитивно понятным способом узнать о различиях между предполагаемыми геометриями лигандов или узнать о важности определенных областей связывания. Для определения того, какие соединения, по прогнозам, будут связываться с мишенью, можно использовать как первичные, так и пересчитанные баллы.

Тран-Нгуен и др. [36] недавно провели сравнение четырех ОФ для повторного измерения положений докинга высоконадежного набора данных скрининга, охватывающего несколько фармацевтических целей. Они обнаружили, что переоценка, основанная на упрощенных ОФ на знаниях, например, измерение отпечатков пальцев взаимодействия, по-видимому, работает лучше, чем современные методы машинного обучения, что показывает важность использования методов переоценки для адекватного обнаружения наиболее мощных связующих веществ. Недавние исследования продемонстрировали, что использование подходов машинного обучения для переоценки результатов докинга значительно повышает производительность структурных моделей, а ансамбли функций переоценки повышают точность прогнозирования. Они пришли к выводу, что использование эмпирических данных для оценки прогнозов докинга является ключевым фактором для улучшения прогнозирования взаимодействий белок-лиганд при разработке лекарственных препаратов.

Таким образом, методы переоценки могут повысить точность результатов докинга, а не сам докинг, являющимся единственным фильтром перед экспериментом. Однако переоценка результирующих позиций, полученных в AutoDock4 [37–39] с помощью XScore [40,41] или DSX [42], улучшила способность модели различать связывающих и не связывающих людей. В нескольких исследованиях использование стратегий консенсуса увеличило площадь под ROC-кривой, что указывает на улучшение дискриминации активных соединений по сравнению с приманками. Методы нормализованного отношения баллов (NSR, Normalized Scores Ratio), ранжирования по числу (RBN, Range Based on Number), ранжирования по рангу (RBR, Range Based on Range) и Z-оценки превосходят любое индивидуальное программное обеспечение для докинга.

Заключение

Не существует универсальной идеальной ОФ, которая могла бы хорошо работать для любого вычисления молекулярного докинга. Таким образом, исследователям приходится разрабатывать ОФ для конкретной цели, используя арсенал возможностей современной математики, биофизики и кибернетики. Новые классы характеристик (межмолекулярные характеристики, характеристики, связанные только с лигандами и белками) могут быть использованы для улучшения производительности ОФ. Эффективность скрининга многозадачной ОФ существенно выше, чем у однозадачной нейронной сети. Разрыв в производительности между двумя функциями гораздо меньше для задач докинга и подсчета очков, с небольшим преимуществом при традиционном подходе с одной задачей. Рост производительности будет гораздо более значительным, если данные оценки, скрининга и докинга будут более разнообразными и объемными.

Значительным фактором, влияющим на различия в производительности, могут быть инструменты докинга и итоговое качество моделей докинга, используемых для обучения моделей. Различные методы используют различные инструменты докинга для создания моделей докинга для своих инструментов оценки. Характеристики состава и качества данных играют решающую роль в определении общей эффективности модели, поскольку они напрямую влияют на способность модели улавливать значимые закономерности и делать точные прогнозы.

Общая эффективность различных ОФ сопоставима при различении активных и ложных целей. Однако результаты могут существенно различаться в зависимости от типа мишени и лиганда. Например, ChemScore [43] дает значительно лучшие результаты, за ним следует Vina [44, 45]. Из-за недостаточной точности функций подсчета баллов лучшие решения типичной кампании виртуального скрининга включают в себя большое количество соединений, которые при экспериментальном тестировании не связываются прочно с мишенью (т.е. дают ложноположительные результаты). В целом было показано, что точность различных программ докинга и функций оценки зависит от конкретного изучаемого белка-мишени и типа лигандов. Связывающие карманы в разных белках различаются по размеру, полярности, доступности растворителя, составу аминокислотных остатков и, что наиболее важно, по количеству, типу и ориентации специфических доступных групп взаимодействия. Лиганды могут существенно различаться по размеру, длине, полярности и гидрофобности, количеству вращающихся связей, количеству возможных доноров или акцепторов водорода и т. д. Сочетание этих особенностей приводит к тому, что перед программой докинга могут стоять совершенно разные задачи, и лучшее решение для решения одной проблемы не обя-

зательно будет лучшим решением для решения другой проблемы.

Среди всех классических алгоритмов и инструментов оценки моделей докинга белков AP-PISA оказался наиболее эффективным методом во всех восьми наборах данных. В отличие от других классических методов, которые в основном рассматривают потенциалы на уровне остатков, AP-PISA переоценивает уточненные модели докинга, используя комбинацию атомных и остаточных потенциалов, что помогает более точно определять почти нативные позиции.

Однако AP-PISA модель опирается исключительно на потенциальные характеристики, но включение энергетических характеристик может повысить производительность за счет использования эмпирических и основанных на знаниях характеристик [17].

По метрике AUC (Area under Curve – площадь под кривой) метод CP-PIE оказался вторым лучшим классическим методом и лучшим по ранжирующей способности. CP-PIE эффективно отфильтровывает маловероятные позиции докинга перед выполнением ресурсоемких вычислений. Он отбрасывает неправильно стыкованные структуры, измеряя область перекрытия между белками в каждой модели докинга. Один из вы-

водов, который можно сделать, заключается в том, что на этапе уточнения удаление позиций, которые далеки от правильных, может иметь решающее значение для точной оценки моделей докинга [17].

Известно, что AP-PISA (Atomic Potential Protein Interfaces, Surfaces and Assemblies) и CP-PIE (Coarse-grained Potentials – Protein Interaction Energy) относятся к числу известных классических функций для распознавания правильных моделей белковых комплексов. AP-PISA – оценка на основе атомных потенциалов, учитывающая расположение и свойства отдельных атомов белка. CP-PIE – крупнозернистая (упрощенная) оценка, основанная на вычислении энергии белкового взаимодействия и учете площади перекрытия взаимодействующих молекул.

Поскольку структурная биоинформатика и молекулярное моделирование продолжают развиваться благодаря технологиям искусственного интеллекта и глубокому обучению, в частности, крайне важно оценивать как классические, так и подходы глубокого обучения с использованием различных наборов данных и конкретных предварительно выбранных целей, чтобы в итоге обеспечить последовательное, эффективное и справедливое сравнение результатов моделирования.

ЛИТЕРАТУРА / REFERENCES

1. Ugbaja S.C., Mushebenge A.G.-A., Kumalo H., Ngcobo M., Gqaleni N. Potential benefits of in silico methods: A promising alternative in natural compound's drug discovery and repurposing for HBV therapy. *Pharmaceuticals*. 2025;18(3):419. <https://doi.org/10.3390/ph18030419>.
2. Tanoli Z., Fernández-Torras A., Özcan U.O., Kushnir A., Nader K.M., Gadiya Y., et al. Computational drug repurposing: Approaches, evaluation of in silico resources and case studies. *Nature Reviews Drug Discovery*. 2025;24(7):521–542. <https://doi.org/10.1038/s41573-025-01164-x>.
3. Kalsi P., Jain P., Goyal G., Sharma H. In silico drug repurposing approach to predict most effective HAART for HIV drug resistance variants prevalent in the Indian HIV-positive population. *AIDS Reviews*. 2024;26(3):93–101. <https://doi.org/10.24875/AIDSRev.24000010>.
4. Hussein D., Almatrafi A., Gomaa M., Alhowsawi A., Almustafa S., Alsaihaty H., et al. In silico drug repurposing using molecular docking and dynamics to target the protein interaction between the SARS-CoV-2 S-glycoprotein and the ACE2 receptor. *F1000Research*. 2024;12:1452. <https://doi.org/10.12688/f1000research.131508.2>.
5. Bhaskar V., Kumar S., Sujathan Nair A., Gokul S., Rajappan Krishnendu P., Benny S., et al. In silico development of potential InhA inhibitors through 3D-QSAR analysis, virtual screening and molecular dynamics. *Journal of Biomolecular Structure & Dynamics*. 2025;43(3):1329–1351. <https://doi.org/10.1080/07391102.2023.2291549>.
6. Moulishankar A., Sankaranarayanan M., Thirugnanasambandam S., Dhamotharan J., Mohanradja D., Sivakumar P.M. Identification of novel DNA gyrase inhibitor by combined pharmacophore modeling, QSAR analysis, molecular docking, molecular dynamics, ADMET and DFT approaches. *Acta Tropica*. 2024;260:107460. <https://doi.org/10.1016/j.actatropica.2024.107460>.
7. Agarwal S., Verma E., Kumar V., Lall N., Sau S. Iyer Arun K., et al. An integrated computational approach of molecular dynamics simulations, receptor binding studies and pharmacophore mapping analysis in search of potent inhibitors against tuberculosis. *Journal of Molecular Graphics and Modelling*. 2018;83:17–32. <http://hdl.handle.net/2263/66564>.
8. Blanes-Mira C., Fernández-Aguado P., de Andrés-López J., Fernández-Carvajal A., Ferrer-Montiel A., Fernández-Ballester G. Comprehensive survey of consensus docking for high-throughput virtual screening. *Molecules*. 2023;28(1):175. <https://doi.org/10.3390/molecules28010175>.
9. Drakontaeidi A., Pontiki E.A. Review on molecular docking on HDAC isoforms: Novel tool for designing selective inhibitors. *Pharmaceuticals*. 2023;16(12):1639. <https://doi.org/10.3390/ph16121639>.
10. Scior T., Bender A., Tresadern G., Medina-Franco J.L., Martinez-Mayorga K., Langer T. Recognizing pitfalls in virtual screening: A critical review. *Journal of Chemical Information and Modeling*. 2012;52(4):867–881. <https://doi.org/10.1021/ci200528d>.

11. Lavecchia A., Di Giovanni C. Virtual screening strategies in drug discovery: A critical review. *Current Medicinal Chemistry*. 2013;20(23):2839–2860. <https://doi.org/10.2174/09298673113209990001>.
12. Murugan N.A., Podobas A., Gadioli D., Vitali E., Palermo G., Markidis S. A review on parallel virtual screening softwares for high-performance computers. *Pharmaceutics*. 2022;15(1). <https://doi.org/10.3390/ph15010063>.
13. Shirali A., Stebliankin V., Shi J., Narasimhan G. A comprehensive survey of scoring functions for protein docking models. *bioRxiv*. 2023.12.29.573663. <https://doi.org/10.1101/2023.12.29.573663>.
14. Guedes I.A., Pereira F.S., Dardenne L.E. Empirical scoring functions for structure-based virtual screening: applications, critical aspects, and challenges. *Frontiers in Pharmacology*. 2018;9:1089. <https://doi.org/10.3389/fphar.2018.01089>.
15. Liu, J., Wang, R. Classification of current scoring functions. *Journal of Chemical Information and Modeling*. 2015;55(3):475–482. <https://doi.org/10.1021/ci500731a>.
16. Balamurugan S., Krishnan A.T., Goyal D., Chandrasekaran B., Pandi B. *Computation in Bioinformatics: Multidisciplinary Applications*. John Wiley & Sons; 2021.
17. Shirali A., Stebliankin V., Karki U., Shi J., Chapagain P., Narasimhan G. A comprehensive survey of scoring functions for protein docking models. *BMC Bioinformatics*. 2025;26:25. <https://doi.org/10.1186/s12859-024-05991-4>.
18. Li J., Fu A., Zhang L. An overview of scoring functions used for protein-ligand interactions in molecular docking. *Interdisciplinary Sciences Computational Life Sciences*. 2019;11(2):320–328. <https://doi.org/10.1007/s12539-019-00327-w>.
19. Boeckler F.M., Bauer M.R., Ibrahim T.M., Vogel S.M. Use of DEKOIS 2.0 to gain insights for virtual screening. *Journal of Cheminformatics*. 2014;6(Suppl 1):O24. <https://doi.org/10.1186/1758-2946-6-S1-O24>.
20. Cleves A.E., Jain A.N. Structure- and ligand-based virtual screening on DUD-E(+): performance dependence on approximations to the binding pocket. *Journal of Chemical Information and Modeling*. 2020;60(9):4296–4310. <https://doi.org/10.1021/acs.jcim.0c00115>.
21. Eldridge M.D., Murray C.W., Auton T.R., Paolini G.V., Mee R.P. Empirical scoring functions: I. The development of a fast empirical scoring function to estimate the binding affinity of ligands in receptor complexes. *Journal of Computer-Aided Molecular Design*. 1997;11(5):425–445. <https://doi.org/10.1023/A:1007996124545>.
22. Murray C.W., Auton T.R., Eldridge M.D. Empirical scoring functions. II. The testing of an empirical scoring function for the prediction of ligand-receptor binding affinities and the use of Bayesian regression to improve the quality of the model. *Journal of Computer-Aided Molecular Design*. 1998;12(5):503–519. <https://doi.org/10.1023/A:1008040323669>.
23. Wang R., Lai L., Wang S. Further development and validation of empirical scoring functions for structure-based binding affinity prediction. *Journal of Computer-Aided Molecular Design*. 2002;16(1):11–26. <https://doi.org/10.1023/A:1016357811882>.
24. de Azevedo Jr. W.F., Dias R. Evaluation of ligand-binding affinity using polynomial empirical scoring functions. *Bioorganic & Medicinal Chemistry*. 2008;16(20):9378–9382. <https://doi.org/10.1016/j.bmc.2008.08.014>.
25. Dias R., Timmers L.F., Caceres R.A., de Azevedo Jr. W.F. Evaluation of molecular docking using polynomial empirical scoring functions. *Current Drug Targets*. 2008;9(12):1062–1070. <https://doi.org/10.2174/138945008786949450>.
26. Korb O., Stutzle T., Exner T.E. Empirical scoring functions for advanced protein-ligand docking with PLANTS. *Journal of Chemical Information and Modeling*. 2009;49(1):84–96. <https://doi.org/10.1021/ci800298z>.
27. Liu Z., Malone B., Yuan C. Empirical evaluation of scoring functions for Bayesian network model selection. *BMC Bioinformatics*. 2012;13(Suppl 15):S14. <https://doi.org/10.1186/1471-2105-13-S15-S14>.
28. Zulhafiz N.A., Teoh T.C., Chin A.V., Chang S.W. Drug repurposing using artificial intelligence, molecular docking, and hybrid approaches: A comprehensive review in general diseases vs Alzheimer's disease. *Comput Methods Programs Biomedicine*. 2025;261:108604. <https://doi.org/10.1016/j.cmpb.2025.108604>.
29. Fujimoto K.J., Minami S., Yanai T. Machine-learning- and knowledge-based scoring functions incorporating ligand and protein fingerprints. *ACS Omega*. 2022;7(22):19030–19039. <https://doi.org/10.1021/acsomega.2c02822>.
30. Guedes I.A., Barreto A.M.S., Marinho D., Krempser E., Kuenemann M.A., Sperandio O., et al. New machine learning and physics-based scoring functions for drug discovery. *Scientific Reports* 2021;11(1):3198. <https://doi.org/10.1038/s41598-021-82410-1>.
31. Bitencourt-Ferreira G., Rizzotto C., de Azevedo Junior W.F. Machine learning-based scoring functions, development and applications with SANdReS. *Current Medicinal Chemistry*. 2021;28(9):1746–1756. <https://doi.org/10.2174/0929867327666200515101820>.
32. Betzi S., Suhre K., Chetrit B., Guerlesquin F., Morelli X. GFScore: A general nonlinear consensus scoring function for high-throughput docking. *Journal of Chemical Information and Modeling*. 2006;46(4):1704–1712. <https://doi.org/10.1021/ci0600758>.
33. Bar-Haim S., Aharon A., Ben-Moshe T., Marantz Y., Senderowitz H. SeleX-CS: A new consensus scoring algorithm for hit discovery and lead optimization. *Journal of Chemical Information*. 2009;49(3):623–633. <https://doi.org/10.1021/ci800335j>.
34. Plewczynski D., Lazniewski M., von Grotthuss M., Rychlewski L., Ginalski K. VoteDock: Consensus docking

method for prediction of protein-ligand interactions. *Journal of Computational Chemistry*. 2011;32(4):568–581. <https://doi.org/10.1002/jcc.21642>.

35. Meli R., Morris G.M., Biggin P.C. Scoring functions for protein-ligand binding affinity prediction using structure-based deep learning: A review. *Frontiers in Bioinformatics*. 2022;2:885983. <https://doi.org/10.3389/fbinf.2022.885983>.

36. Tran-Nguyen V.-K., Bret G., Rognan D. True accuracy of fast scoring functions to predict high-throughput screening data from docking poses: The simpler the better. *Journal of Chemical Information and Modeling*. 2021;61(6):2788–2797. <https://doi.org/10.1021/acs.jcim.1c00292>.

37. Morris G.M., Huey R., Lindstrom W., Sanner M.F., Belew R.K., Goodsell D.S., et al. AutoDock4 and AutoDockTools4: Automated docking with selective receptor flexibility. *Journal of Computational Chemistry*. 2009;30(16):2785–2791. <https://doi.org/10.1002/jcc.21256>.

38. Bitencourt-Ferreira G., Pinto V.O., de Azevedo Jr. W.F. Docking with AutoDock4. In: de Azevedo Jr. W. (eds) *Docking Screens for Drug Discovery. Methods in Molecular Biology*, Volume 2053. Humana, New York; 2019. pp. 125–148. https://doi.org/10.1007/978-1-4939-9752-7_9.

39. Santos-Martins D., Solis-Vasquez L., Tillack A.F., Sanner M.F., Koch A., Forli S. Accelerating AutoDock4 with GPUs and gradient-based local search. *Journal of Chemical Theory and Computation*. 2021;17(2):1060–1073. <https://doi.org/10.1021/acs.jctc.0c01006>.

40. Obiol-Pardo C., Rubio-Martinez J. Comparative evaluation of MMPBSA and XSCORE to compute binding free energy in XIAP-peptide complexes. *Journal of Chemical Information and Modeling*. 2007;47(1):134–142. <https://doi.org/10.1021/ci600412z>.

41. Pencheva T., Soumana O.S., Pajeva I., Miteva M.A. Post-docking virtual screening of diverse binding pockets: Comparative study using DOCK, AMMOS, X-Score and FRED scoring functions. *European Journal of Medicinal Chemistry*. 2010;45(6):2622–2628. <https://doi.org/10.1016/j.ejmech.2009.12.025>.

42. Neudert G., Klebe G. DSX: A knowledge-based scoring function for the assessment of protein-ligand complexes. *Journal of Chemical Information and Modeling*. 2011;51(10):2731–2745. <https://doi.org/10.1021/ci200274q>.

43. Wang W.J., Huang Q., Zou J., Li L.L., Yang S.Y. TS-Chemscore, a Target-Specific Scoring Function, Significantly Improves the Performance of Scoring in Virtual Screening. *Chemical Biology & Drug Design*. 2015;86(1):1–8. <https://doi.org/10.1111/cbdd.12470>.

44. Eberhardt J., Santos-Martins D., Tillack A.F., Forli S. AutoDock Vina 1.2.0: New docking methods, expanded force field, and Python bindings. *Journal of Chemical Information and Modeling*. 2021;61(8):3891–3898. <https://doi.org/10.1021/acs.jcim.1c00203>.

45. Lu H., Wei Z., Wang C., Guo J., Zhou Y., Wang Z., et al. Redesigning Vina@QNLN for ultra-large-scale molecular docking and screening on a Sunway supercomputer. *Frontiers in Chemistry*. 2021;9:750325. <https://doi.org/10.3389/fchem.2021.750325>.

M. V. SPRINDZUK ¹⁾, V. V. KUKARTSEV ^{2,3)}, A. V. NOZDRACHEVA ⁴⁾, A. P. KONCHITS ⁵⁾, A. S. VLADYKO ⁶⁾,
V. I. BERNIK ⁷⁾, E. I. SUKACH ⁸⁾

SCORING FUNCTIONS OF MOLECULAR PROTEIN DOCKING MODELS: CLASSIFICATION AND APPLICATION IN BIOINFORMATICS

¹⁾ United Institute of Informatics Problems of the National Academy of Sciences of Belarus
Minsk, Republic of Belarus

²⁾ Russian State Agrarian University – Moscow Timiryazev Agricultural Academy
Moscow, Russian Federation

³⁾ Bauman Moscow State Technical University
Moscow, Russian Federation

⁴⁾ National Research Center for Epidemiology and Microbiology named after Honorary Academician
N. F. Gamaleya of the Ministry of Health of the Russian Federation, Moscow

⁵⁾ Institute of Forestry of the National Academy of Sciences of Belarus
Gomel, Republic of Belarus

⁶⁾ Scientific Research Institute of Hygiene, Toxicology, Epidemiology, Virology and Microbiology,
state institution “Republican Center of Hygiene, Epidemiology and Public Health”
Minsk, Republic of Belarus.

⁷⁾ Institute of Mathematics of the National Academy of Sciences of Belarus
Minsk, Republic of Belarus

⁸⁾ Francisk Skorina Gomel State University
Gomel, Republic of Belarus

Abstract. *This review article presents a generalized, integrated classification of scoring functions for molecular docking of protein interaction models. It describes various types of scoring functions and reports relevant issues in biopharmaceuticals, medical cybernetics, computational biology and biophysics, applied mathematics. This article may be of interest to a wide range of readers, including scientists from various fields, software engineers, developing automated bioinformation processing systems, lecturers on relevant topics, graduate and postgraduate students in bioinformatics, systems analysis, medical software systems research.*

Keywords: *molecular docking, medical cybernetics, computational biology, genomics, pattern recognition, artificial intelligence, bioinformatics, computational analysis, applied mathematics, medical computer systems, scoring software tools, hardware and software engineering*

Спринджук М. В.

Объединенный институт проблем информатики Национальной академии наук Беларуси (ОИПИ НАН Беларуси), ул. Сурганова, 6, 220072, г. Минск, Республика Беларусь.

Кандидат технических наук, старший научный сотрудник ОИПИ НАН Беларуси.

M. V. Sprindzuk

United Institute of Informatics Problems of the National Academy of Sciences of Belarus (UIIP NAS Belarus), Sarganova St., 6, 220072, Minsk, Republic of Belarus.

PhD (Technical Sciences, Informatics, Engineering), Senior Researcher at the United Institute of Informatics Problems of the National Academy of Sciences of Belarus.

E-mail: stepanenkomatvei@yandex.ru

<https://orcid.org/0000-0001-9500-2954>

Tel: +375 33 682 57 55

Кукарцев В. В.

Российский государственный аграрный университет — МСХА им. К. А. Тимирязева, г. Москва, Российская Федерация

Московский государственный технический университет им. Н. Э. Баумана, г. Москва, Российская Федерация.

Кандидат технических наук, доцент.

V. V. Kukartsev

Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RSAU-MTAA), Moscow, Russian Federation.

Bauman Moscow State Technical University, Moscow, Russian Federation.

PhD (Technical Sciences, Informatics, Engineering), Associate Professor.

E-mail: vlad_saa_2000@mail.ru

<https://orcid.org/0000-0001-6382-1736>

Ноздрачева А. В.

Национальный исследовательский центр эпидемиологии и микробиологии имени почётного академика Н. Ф. Гамалеи Минздрава России, г. Москва.

Кандидат медицинских наук, доцент.

A. V. Nozdracheva

National Research Center for Epidemiology and Microbiology named after Honorary Academician N. F. Gamaleya of the Ministry of Health of the Russian Federation, Moscow.

PhD in Medical Sciences, Associate Professor.

E-mail: nozdracheva0506@gmail.com

<https://orcid.org/0000-0002-8521-1741>

Кончиц А. П.

Институт леса Национальной академии наук Беларуси, г. Гомель, Республика Беларусь.

Кандидат биологических наук, ведущий научный сотрудник.

A. P. Konchits

Institute of Forestry of the National Academy of Sciences of Belarus, Gomel, Republic of Belarus.

PhD in Biology, Leading Researcher.

E-mail: konchits@yandex.ru

<https://orcid.org/0000-0002-8823-0630>

Владыко А. С.

Научно-исследовательский институт гигиены, токсикологии, эпидемиологии, вирусологии и микробиологии государственного учреждения «Республиканский центр гигиены, эпидемиологии и общественного здоровья», г. Минск, Республика Беларусь.

Доктор медицинских наук. Внештатный научный консультант.

A. S. Vladyko

Scientific Research Institute of Hygiene, Toxicology, Epidemiology, Virology and Microbiology State Institution "Republican Center of Hygiene, Epidemiology and Public Health", Minsk, Republic of Belarus.

Doctor of Medical Sciences. Freelance Scientific Consultant.

<https://orcid.org/0000-0001-6927-5043>

Берник В. И.

Институт математики Национальной академии наук Беларуси, ул. Сурганова, 11, 220072, г. Минск, Республика Беларусь.

Доктор физико-математических наук, профессор. Главный научный сотрудник отдела теории чисел.

V. I. Bernik

Institute of Mathematics of the National Academy of Sciences of Belarus, Surganova St., 11, 220072, Minsk, Republic of Belarus.

Doctor of Physical and Mathematical Sciences, Professor. Chief Researcher of the Department of Number Theory.

E-mail: bernik@im.bas-net.by

<https://orcid.org/0000-0001-8096-1079>

Сукач Е. И.

Гомельский государственный университет имени Франциска Скорины, г. Гомель, Республика Беларусь.

Кандидат технических наук, доцент.

E. I. Sukach

Francisk Skorina Gomel State University, Gomel, Republic of Belarus.

PhD (Technical Sciences, Informatics, Engineering), Associate Professor.

E-mail: eisukach@gsu.by

E-mail: elena.sukach@mail.ru

<https://orcid.org/0000-0002-3693-1494>

Исследование выполнено при поддержке грантов ISTC PRI50, Advancing Data Integration, AI-Based Image Analysis, and Genomic Research in Belarus, а также государственных научных программ ОИПИ НАН Беларуси.

ОЛЬГА ГОЛДА

СИСТЕМНО-ДИНАМИЧЕСКИЙ ПОДХОД К МОДЕЛИРОВАНИЮ ОРГАНИЗАЦИОННОЙ МОДЕЛИ УПРАВЛЕНИЯ ПРОИЗВОДСТВОМ ПРОМЫШЛЕННОГО ПРЕДПРИЯТИЯ

Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

Аннотация. В статье рассматривается подход к проектированию и анализу организационной модели управления производством промышленного предприятия на основе когнитивного и имитационного моделирования. Актуальность исследования обусловлена необходимостью совершенствования систем управления промышленными предприятиями в условиях высокой вариативности внешней среды, усложнения производственно-управленческих связей и недостаточности статических оптимизационных моделей для описания динамики организационных процессов. Целью работы является формализация организационной модели управления производством металлургического предприятия с использованием диаграммы причинно-следственных связей и ее последующая реализация в среде имитационного моделирования. В исследовании применены методы системного анализа, экономико-математического, когнитивного и системно-динамического моделирования. Организационная структура предприятия представлена как совокупность производственной и функциональной подсистем, связанных вертикальными и горизонтальными управленческими взаимодействиями, а ключевыми параметрами модели выступают норма управляемости, затраты на содержание управленческого аппарата, производственные мощности, объемы реализации и чистая прибыль. Построенная когнитивная карта позволила выявить основные причинно-следственные зависимости между организационными, производственными и финансовыми параметрами предприятия, а имитационная модель – оценить влияние управленческих решений на динамику затрат и финансовых результатов. Полученные результаты показывают, что использование когнитивных карт в сочетании с имитационным моделированием расширяет возможности анализа устойчивости организационной структуры и обоснования решений по ее совершенствованию. Практическая значимость работы состоит в возможности применения предложенного подхода при проектировании и корректировке систем управления металлургических и иных промышленных предприятий.

Ключевые слова: когнитивное моделирование, когнитивная карта, имитационное моделирование, системная динамика, организационная модель управления, промышленное предприятие, управление производством

Введение

В современных условиях усиления конкурентной борьбы и высокой вариативности внешней среды особую значимость приобретает совершенствование систем управления производством на промышленных предприятиях.

Эффективная система управления наиболее востребована на предприятиях, имеющих сложную иерархическую систему управления (большим количеством уровней иерархии) с линейно-функциональной структурой, высокой степенью централизации и акцентом на управление непрерывными производственными процессами (металлургическая, нефтехимическая и нефтеперерабатывающая отрасли, цементные и горнодобывающие комбинаты, энергетические предприятия). Традиционные подходы к организационному проектированию, опирающиеся преимущественно на статические оптимизационные модели, оказываются недостаточными для адекватного отражения сложных взаимосвязей между элементами производственно-управленческой системы и не позволяют в полной мере учитывать динамику изменений во времени. Это создает необходимость в инструментах, способных инте-

грировать экономико-математическое моделирование с системным и системно-динамическим подходами к управлению.

Одним из инструментов являются когнитивные карты или диаграммы причинно-следственных связей, позволяющие формализовать структуру экономической системы, отразить направленность и силу влияний между ее элементами, а также выделить ключевые контуры обратной связи. Для металлургических предприятий, рассматриваемых в статье в качестве примера, характеризующихся большим масштабом производства, сложной технологической структурой и высокой капиталоемкостью, когнитивные модели дают возможность анализировать влияние организационных решений на финансовые результаты и устойчивость функционирования, а также формировать сценарии развития с учетом взаимозависимости управленческих и производственных параметров.

Традиционно исследования в области моделирования организационных структур промышленных предприятий опираются на методы теории графов, системного анализа и оптимизации иерархий [1, 2]. Организационная структура рассматривается как ориентированный ациклический граф, вершины которого

описывают исполнителей и менеджеров, а дуги – отношения подчиненности и информационные связи. Значительное внимание уделяется норме управляемости и распределению функций между уровнями иерархии как ключевым факторам эффективности.

Развитие используемого нами системно-динамического подхода позволило перейти от статического анализа к исследованию поведения сложных организационно-производственных систем во времени [3]. В рамках этого подхода широко применяются диаграммы влияний и когнитивные карты, описывающие причинно-следственные связи между ресурсами, потоками, результатами и управленческими решениями. Исследования в области моделирования организационных структур металлургических предприятий [4, 5] демонстрируют целесообразность использования интеграции оптимизационных и имитационных моделей, в том числе на базе специализированных пакетов структурного моделирования, для оценки влияния организационных изменений на производственные показатели и чистую прибыль предприятия. Когнитивные карты выступают ключевым инструментом формализации структуры системы и постановки задачи имитационного эксперимента.

В смежных прикладных исследованиях развитие методов моделирования сложных систем связано также с учетом неопределенности, нечеткости и неполноты исходной информации. Так, в работе показано, что для слабоструктурированных производственных процессов целесообразно использовать интеграцию логико-динамических и нечетко-вероятностных моделей, позволяющую учитывать влияние различных факторов неопределенности на устойчивость и качество принимаемых решений [6]. Дополнительный методологический интерес представляют исследования, ориентированные на формирование и уточнение исходных данных модели. В частности, в работе предложен подход, основанный на применении нечеткой кластеризации и системы показателей качества, обеспечивающий более обоснованный выбор исходных данных и повышение достоверности результатов моделирования и анализа [7].

Основная часть

Для описания работы промышленного предприятия со сложной иерархической структурой и моделирования процессов управления производством выбрана организационная модель управления производством металлургического предприятия [8].

Модель формируется в условиях необходимости обеспечения

- устойчивости режима функционирования,
- адаптивности к изменениям внешней среды,
- минимизации управленческих затрат.

В соответствии с требованиями к рациональным организационным структурам данная модель должна характеризоваться

- функциональностью,
- экономичностью,
- избыточностью,
- устойчивостью,
- стратегической направленностью.

Такая структура управления должна обеспечивать согласованность работы менеджеров и исполнителей, минимальные расходы на выполнение управленческих функций, достаточную глубину иерархии без избыточного числа уровней, а также способность к адаптации при изменении рыночных условий.

С точки зрения формализации организационная модель описывается как иерархическая структура, в которой выделяются множество исполнителей производственной подструктуры и множество менеджеров функциональной подструктуры [9].

Между ними устанавливаются вертикальные и горизонтальные связи, для характеристики интенсивности которых выбраны:

- количество передаваемой документации,
- число контактов, не связанных с документооборотом.

Эти характеристики формируют функцию затрат на содержание аппарата управления, зависящую от количества принимаемых менеджерами решений, нормы управляемости и параметров сжатия информации о проблемах в группе исполнителей.

$$H' \in \text{Arg min } C(H),$$

$$C: \Psi \rightarrow [0, +\infty),$$

$$\Psi \subseteq \Psi(N),$$

где H' – оптимальная иерархическая структура предприятия; $C(H)$ – функция затрат, ставящая в соответствие каждой допустимой иерархии положительное число; Ψ – множество допустимых иерархий, которые управляют множеством исполнителей.

Обеспечение бесперебойного технологического процесса осуществляется за счет принятия m -м менеджером D решений в единицу времени. Тогда затраты на содержание m -го менеджера можно представить в виде:

$$c_m = D^{\varphi_m},$$

где c_m – затраты на содержание m -го менеджера, $c_m \in C$; φ_m – параметр, который описывает скорость роста затрат на содержание m -го менеджера, $\varphi_m \geq 1$. При этом, чем меньше параметр φ , тем больше эффективность деятельности m -го менеджера, так как при принятии совокупности решений D он несет меньшие затраты для металлургического предприятия.

В каждой из функциональных зон, обеспечивающих осуществление производственного процесса, в единицу времени может возникать определенное число проблем, которые являются мерой управляемости каждого отдельного n -го исполнителя.

Соответственно, количество проблем, возникающих в единицу времени у группы исполнителей, равно:

$$P = \sum_{n=1}^N \rho(u_n^\beta),$$

где P – мера управляемости группы исполнителей; $\rho(u_n^\beta)$ – мера управляемости n -го исполнителя; β – параметр сжатия информации о проблемах в отчете каждого n -го исполнителя. При этом параметр $\beta \in [0, 1]$ характеризует однотипность проблем, возникающих у каждого n -го исполнителя, и определяет степень стабильности производственного процесса. Интерпретация значений параметра β может быть представлена следующим образом:

– при $\beta = 0$ отчет группы исполнителей свидетельствует об отсутствии проблем в ходе осуществления производственного процесса металлургического предприятия;

– при $\beta \in (0, 1)$ в отчете группы исполнителей присутствуют однотипные проблемы, в результате чего объем отчета о работе данной группы исполнителей не определяется числом исполнителей и принимает значение меньше единицы;

– при $\beta = 1$ отчет группы исполнителей свидетельствует о наличии серьезных проблем в ходе осуществления производственного процесса металлургического предприятия.

С учетом вышеизложенного затраты на содержание m -го менеджера, которому подчинено n исполнителей, можно найти в соответствии с выражением:

$$c_m = \sum_{n=1}^N [\rho(u_n^\beta)]^{p_m}.$$

В рамках экономико-математического описания организационной модели ставится задача поиска оптимальной иерархии, обеспечивающей минимизацию совокупных затрат при заданных ограничениях по производственной мощности, трудовым и материально-сырьевым ресурсам, а также по норме управляемости менеджеров. В качестве результирующего финансового показателя рассматривается чистая прибыль предприятия, рассчитываемая с учетом выручки от реализации продукции, производственных и непроизводственных затрат, расходов на содержание персонала, капитальных вложений и обязательных платежей [10].

$$\begin{aligned} Net Profit = & \sum_{i=1}^I \sum_{t=1}^T x(i, t) \cdot p(i, t) - \sum_{n=1}^N \sum_{i=1}^I \sum_{t=1}^T x(i, t) \cdot e(n, i, t) - \\ & - \sum_{m=1}^M \sum_{t=1}^T c_m(t) - \sum_{i=1}^I \sum_{t=1}^T x(i, t) \cdot w(i, t) - \sum_{t=1}^T f(t) - \\ & - \sum_{t=1}^T k(t) - \sum_{t=1}^T a(t) \rightarrow \max \\ & i = \overline{1, I}, t = \overline{1, T}, n = \overline{1, N}, m = \overline{1, M}, \end{aligned}$$

где $Net Profit$ – чистая прибыль металлургического предприятия; $c_m(t)$ – затраты на содержание m -го менеджера в период времени t ; $x(i, t)$ – объем производства i -го вида продукции в период времени t ; $p(i, t)$ – цена реализации i -го вида продукции в период времени t ; $e(n, i, t)$ – текущие затраты на производство и реализа-

цию n -м исполнителем i -го вида продукции в период времени t ; $w(i, t)$ – затраты на производство и реализацию i -го вида продукции в период времени t , образующие себестоимость, но не относимые ни к одному исполнителю n ; $f(t)$ – затраты на расширение и обновление производства в период времени t ; $k(t)$ – непроизводственные затраты металлургического предприятия в период времени t ; $a(t)$ – сумма налогов, пеней, штрафов и процентов по кредитам в период времени t .

Таким образом, организационная модель управления производством включается в структуру общей модели синергетического эффекта функционирования металлургического предприятия и оказывает непосредственное влияние на его рентабельность.

Рассмотренная оптимизационная постановка задачи проектирования организационной модели управления производством ориентирована на одномоментный срез информации и поиск оптимального решения для фиксированного набора параметров. Однако в реальных условиях функционирования металлургического предприятия внешняя и внутренняя среда подвержены существенным изменениям, что приводит к изменению интенсивности производственных и финансовых потоков, структуры затрат, парка оборудования и кадрового состава. В этих условиях использование исключительно статических оптимизационных моделей не позволяет описывать динамику состояний системы и оценивать устойчивость найденного решения.

Для преодоления указанных ограничений целесообразно применение имитационного моделирования. Этот подход позволяет воспроизводить процесс функционирования экономической системы во времени, сохранять логическую структуру и последовательность ключевых событий, а также формировать сценарии развития при варьировании управленческих решений.

Использование имитационной модели представляет дополнительные преимущества: позволяет учитывать случайные факторы, влияющие на управленческие решения и производственные результаты; проводить эксперименты с изменением структуры организационной иерархии и норм управляемости; анализировать чувствительность итогового финансового результата к изменению ключевых параметров системы. Вместе с тем построение такой модели требует предварительной формализации причинно-следственных связей между структурными элементами организационной системы, для чего используется когнитивное моделирование [11].

Ключевым элементом предлагаемого подхода к проектированию и анализу организационной модели управления производством металлургического предприятия является диаграмма причинно-следственных связей, представляющая собой когнитивную карту системы. В данной диаграмме структурные элементы организационно-производственного комплекса (уровень чистой прибыли, объемы реализации, структура затрат, число исполнителей и менеджеров, норма управляемости, производственные мощности и др.) представлены в виде

вершин, а причинно-следственные связи между ними – в виде ориентированных дуг со знаками влияния [11].

Положительные связи отражают ситуации, когда увеличение значения одного элемента при прочих равных условиях приводит к увеличению (или уменьшению – к уменьшению) значения связанного элемента. Например, рост объемов реализации рентабельных видов продукции при неизменной структуре затрат способствует увеличению величины чистой прибыли. Отрицательные связи характеризуют взаимосвязи, при которых рост одного параметра приводит к снижению другого. Так, увеличение затрат на содержание управленческого аппарата при фиксированном уровне выручки снижает чистую прибыль предприятия. Замкнутые контуры причинно-следственных связей фор-

мируют петли обратной связи, которые в зависимости от произведения знаков входящих в них дуг могут быть положительными (усиливающими) или отрицательными (стабилизирующими).

Структура диаграммы причинно-следственных связей организационной модели управления производством металлургического предприятия сформирована на основе системно-динамического подхода (рис. 1). В ней выделены блоки, отражающие производственную подструктуру (исполнители и производственные мощности), функциональную подструктуру (менеджеры и их управленческая нагрузка), финансовые потоки (выручка, производственные и непроизводственные затраты, капитальные вложения, налоговые платежи), а также результирующий показатель – чистую прибыль.




Рисунок 1. Диаграмма причинно-следственных связей организационной модели управления производством металлургического предприятия (системно-динамический подход)

Особое внимание уделено связям, характеризующим влияние нормы управляемости менеджеров, параметров сжатия информации о проблемах в группах исполнителей и скорости роста затрат на содержание управленческого персонала на величину управленческих расходов и итоговый финансовый результат.

Диаграмма причинно-следственных связей выполняет две функции [12]. Во-первых, она служит инструментом качественного анализа структуры организационной системы: позволяет выявить ключевые переменные, «узкие места», а также контуры, определяющие устойчивость или неустойчивость поведения

системы. Во-вторых, она является исходной основой для построения имитационной модели: на ее базе формируется перечень переменных, задаются направленность и характер связей, выбираются уровневые и потоковые переменные, а также вспомогательные зависимости. Таким образом, диаграмма причинно-следственных связей обеспечивает непрерывность между концептуальным описанием организационной модели и ее количественной реализацией [13].

На основе диаграммы причинно-следственных связей организационная модель управления производством металлургического предприятия реализуется в среде Powersim (рис. 2).




Рисунок 2. Имитационная модель управления производством металлургического предприятия

В качестве объекта моделирования [14] рассматривается металлургическое предприятие с полным технологическим циклом, для которого доступны данные официальной отчетности по объемам выпуска, структуре ассортимента, производственным мощностям, затратам и кадровому составу. В имитационной модели уровень *Net_Profit* отражает накопление чистой прибыли во времени, а потоки *Income* и *Outcome* задают ее прирост и уменьшение в зависимости от управления производством и затратами.

Выручка от реализации (*Income*) формируется из производства объемов поставок отдельных видов продукции на соответствующие цены реализации. Объемы поставок ограничиваются производственной мощностью цехов и ресурсными ограничениями, а также учитывают динамику спроса. Затраты (*Outcome*) агрегируют расходы на производство и реализацию продукции исполнителями, затраты, образующие себестоимость, но не относимые к исполнителям, расходы на содержание менеджеров, капитальные вложения, непроизводительные затраты и обязательные платежи. При этом

значение затрат на содержание менеджеров зависит от количества менеджеров в организационной структуре, их нормы управляемости и скорости роста затрат на содержание каждого менеджера.

Структура имитационной модели соответствует блокам, выделенным в диаграмме причинно-следственных связей: производственный блок (объемы выпуска, мощности цехов), кадровый блок (число исполнителей и менеджеров, норма управляемости, параметр эффективности менеджеров), финансовый блок (выручка, затраты, чистая прибыль), блок организационных ограничений (трудовые, ресурсные и мощностные ограничения). Использование встроенных функций Powersim позволяет моделировать случайные величины, отражающие вариативность управленческих решений и производственных условий, а также анализировать отклик системы на изменения заданных параметров.

Результаты имитационного моделирования демонстрируют, что сформированная организационная модель управления производством металлургического предприятия соответствует требованиям рациональной

организационной структуры, обеспечивая рост чистой прибыли при приемлемом уровне затрат на содержание аппарата управления. Графики динамики чистой прибыли и затрат, полученные в ходе моделирования, по-

зволяют оценить характер влияния ключевых факторов на финансовые результаты предприятия и выделить диапазоны параметров, в которых система сохраняет устойчивость (рис. 3).




Рисунок 3. Результаты реализации организационной модели управления производством в среде Powersim

Анализ поведения модели показывает, что норма управляемости менеджеров и параметры сжатия информации о проблемах в группах исполнителей оказывают существенное влияние на величину управленческих затрат. Увеличение нормы управляемости при неизменной эффективности менеджеров и структуре проблем позволяет сократить численность управленческого персонала, однако при превышении определенного порогового значения приводит к росту атипичности проблем и увеличению объема работы менеджеров, что, в свою очередь, повышает затраты на содержание управленческого аппарата. Таким образом, оптимальная норма управляемости определяется компромиссом между сокращением численности менеджеров и сохранением приемлемого уровня управленческих затрат.

Когнитивная карта и соответствующая ей имитационная модель позволяют также оценить влияние инвестиционных решений на долгосрочную динамику чистой прибыли. Увеличение затрат на расширение и обновление производства в краткосрочной перспективе снижает текущую прибыль, однако при соответствующем росте производственных мощностей и объемов реализации рентабельной продукции приводит к улучшению финансовых результатов в долгосрочном периоде. Анализ контуров обратной связи показывает, что положительные петли, связанные с расширением производственных мощностей и ростом выручки, должны быть сбалансированы отрицательными контурами, отражающими ограничения по ресурсам и управленческим возможностям, чтобы избежать неустойчивого роста затрат и потери управляемости системой.

Заключение

Предложенный подход к проектированию организационной модели управления производством металлургического предприятия основан на интеграции экономико-математического моделирования, когнитивных карт и системно-динамического имитационного моделирования. Диаграмма причинно-следственных связей выступает центральным элементом этого подхода, обеспечивая формализацию структуры организационно-производственной системы, выявление ключевых факторов и контуров обратной связи, а также служа основой для построения имитационной модели в среде Powersim.

Результаты моделирования показывают, что использование когнитивных карт и имитационных моделей позволяет более полно учитывать сложные взаимосвязи между организационными, производственными и финансовыми параметрами металлургического предприятия или других типов промышленных предприятий, оценивать влияние управленческих решений на динамику чистой прибыли и затраты, а также формировать рекомендации по оптимизации нормы управляемости, численности персонала и структуры затрат. Практическая значимость предложенного подхода заключается в возможности применения его для обоснования организационных изменений, планирования производственных и инвестиционных решений, а также для разработки стратегий повышения эффективности деятельности металлургических предприятий в условиях нестабильной внешней среды.

ЛИТЕРАТУРА

1. Форрестер, Д. Основы кибернетики предприятия : (индустриальная динамика) / Джей Форрестер. Москва : Прогресс, 1971. 340 с.

2. Гинис, Л. А. Моделирование сложных систем: когнитивный теоретико-множественный подход / Л. А. Гинис, Л. В. Гордиенко. Ростов-на-Дону ; Таганрог : Издательство Южного федерального университета, 2016. 159 с.
3. Стерман, Дж. Бизнес-динамика: системы мышления и моделирование сложного мира / Дж. Стерман. Москва : Альпина Паблишер, 2000. 994 с.
4. Ткаченко, В. А. Моделирование организационной структуры управления на промышленных предприятиях / В. А. Ткаченко, С. И. Чимшит, Е. В. Козлов // *Економічний вісник Донбасу*. 2010. № 3 (21). С. 154–164. URL: https://www.evd-journal.org/download/2010/2010-3/ek_visnyk_3_2010-154-164.pdf (дата обращения: 17.06.2026).
5. Ханина, А. В. Экономика и управление организацией (металлургического профиля) / А. В. Ханина. Москва : КноРус, 2026. 204 с.
6. Consideration of non-factors in complex models of agricultural production / B. Sokolov, A. Spesivtsev, N. Lapitskaya, A. Semyonov // *Robotics in Agriculture (ADOP 2025)*. Springer, 2026. Vol. 453. P. 393–402. DOI: 10.1007/978-3-032-07171-2_32.
7. Zelentsov, V. Methodology for assessing the quality of multispectral space imaging data in landscape element monitoring / V. Zelentsov, V. Mochalov, N. Lapitskaya // *Robotics in Agriculture (ADOP 2025)*. Springer, 2026. Vol. 453. P. 355–366. DOI: 10.1007/978-3-032-07171-2_29.
8. Голда, О. А. Модель управления производством металлургических предприятий / О. А. Голда // Актуальные вопросы современной информатики : материалы V Всероссийской (с международным участием) научно-практической конференции, 1-15 апреля 2015 г. Коломна, 2015. С. 126–130.
9. Минцберг, Г. Структура в кулаке: создание эффективных организаций / Генри Минцберг. СПб. : Питер, 2012. 512 с.
10. Губко, М. В. Оптимальные иерархии управления для функций затрат, представимых в виде суммы однородных функций / М. В. Губко // *Проблемы управления*. 2009. № 3. С. 44–53. URL: <https://cyberleninka.ru/article/n/optimalnye-ierarhii-upravleniya-dlya-funktsiy-zatrat-predstavimyh-v-vide-summy-odnorodnyh-funktsiy> (дата обращения: 19.06.2026).
11. Иванова, О. Е. Когнитивные модели управления затратами промышленных предприятий с идентифицируемыми параметрами / О. Е. Иванова, М. С. Абрашкин, С. И. Польская // *Russian Journal of Management*. 2025. № 7. С. 194–205. DOI: 10.29039/2500-1469-2025-13-7-194-205.
12. Горелова, Г. В. Когнитивное моделирование сложных систем: состояние и перспективы / Г. В. Горелова // Системный анализ в проектировании и управлении : сборник научных трудов XXV Международной научной и учебно-практической конференции, 13–14 октября 2021 г. : в 3 ч. / Международная академия наук высшей школы, Санкт-Петербургское отделение [и др.] ; программный комитет конференции: Ю. С. Васильев (пред.) [и др.] ; отв. ред. В. Н. Волкова, В. Н. Козлов. Санкт-Петербург, 2021. Ч. 1. С. 224–248. DOI: 10.18720/SPBPU/2/id21-66.
13. Когнитивное моделирование экономического развития промышленных экосистем / Е. С. Митяков, Н. Н. Карпухина, С. Н. Митяков, А. И. Ладынин // *Экономика промышленности*. 2025. Т. 18, № 1. С. 63–77. DOI: 10.17073/2072-1633-2025-1-1383.
14. Радаев, А. Е. Имитационное моделирование производственных систем / А. Е. Радаев, В. В. Кобзев. 3-е изд., перераб. и доп. Санкт-Петербург : ПОЛИТЕХ-ПРЕСС, 2022. 136 с.

REFERENCES

1. Forrester J. *Industrial Dynamics*. Moscow: Progress; 1971. 340 p. (in Russian).
2. Gini L.A., Gordienko L.V. *Modeling Complex Systems: A Cognitive Set-Theoretic Approach*. Rostov-on-Don; Taganrog: Yuzhnyi Federal'nyi Universitet Publ.; 2016. 159 p. (in Russian).
3. Sterman J. *Business Dynamics: Systems Thinking and Modeling for a Complex World*. Moscow: Al'pina Publisher; 2000. 994 p. (in Russian).
4. Tkachenko V.A., Chimshit S.I., Kozlov E.V. Design of organizational structure of management on industrial enterprises. *Economic Herald of the Donbas*. 2010;3(21):154–164. Available at: https://www.evd-journal.org/download/2010/2010-3/ek_visnyk_3_2010-154-164.pdf (accessed 17 June 2026) (in Russian).
5. Khanina A.V. *Ehkonomika i upravlenie organizatsiei (metallurgicheskogo profilya) [Economics and Management of the Organization (Metallurgical Profile)]*. Moscow: KnoRus; 2026. 204 p. (in Russian).
6. Sokolov B., Spesivtsev A., Lapitskaya N., Semyonov A // Consideration of non-factors in complex models of agricultural production. *Robotics in Agriculture (ADOP 2025)*. 2026;1:393–402. https://doi.org/10.1007/978-3-032-07171-2_32.
7. Zelentsov V., Mochalov V., Lapitskaya N. Methodology for assessing the quality of multispectral space imaging data in landscape element monitoring. *Robotics in Agriculture (ADOP 2025)*. 2026;1:355–366. https://doi.org/10.1007/978-3-032-07171-2_29.
8. Golda O.A. Model' upravleniya proizvodstvom metallurgicheskikh predpriyatii [Production management mod-

el for metallurgical enterprises]. *Aktual'nye voprosy sovremennoi informatiki [Topical Issues of Modern Informatics]*. 2015;V:126–130 (in Russian).

9. Mintzberg H. *Structure in Fives: Designing Effective Organizations*. St. Petersburg: Piter; 2012. 512 p. (in Russian).

10. Gubko M.V. Optimal hierarchies of control for cost functions representable as a sum of homogeneous functions. *Control Sciences*. 2009;3:44–53. Available at: <https://cyberleninka.ru/article/n/optimalnye-ierarhii-upravleniya-dlya-funktsiy-zatrat-predstavimyh-v-vide-summy-odnorodnyh-funktsiy> (accessed 17 June 2026) (in Russian).

11. Ivanova O.E., Abrashkin M.S., Pol'skaya S.I. Cognitive models of industrial enterprise cost management with identifiable parameters. *Russian Journal of Management*. 2025;7:194–205 (in Russian). <https://doi.org/10.29039/2500-1469-2025-13-7-194-205>.

12. Gorelova G.V. Cognitive modeling of complex systems, state and prospects. *Sistemnyi analiz v proektirovanii i upravlenii [System Analysis in Design and Management]*. 2021;XXV(1):224–248 (in Russian). <https://doi.org/10.18720/SPBPU/2/id21-66>.

13. Mityakov E.S., Karpukhina N.N., Mityakov S.N., Ladynin A.I. Cognitive modelling of economic development of industrial ecosystems. *Russian Journal of Industrial Economics*. 2025;18(1):63–77 (in Russian). <https://doi.org/10.17073/2072-1633-2025-1-1383>.

14. Radaev A.E., Kobzev V.V. *Imitatsionnoe modelirovanie proizvodstvennykh sistem [Simulation Modeling of Production Systems]*. St. Petersburg: POLITEKh-PRESS; 2022. 136 p. (in Russian).

OLGA GOLDA

A SYSTEM DYNAMICS APPROACH TO MODELING THE ORGANIZATIONAL MODEL OF PRODUCTION MANAGEMENT AT AN INDUSTRIAL ENTERPRISE

*Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus*

Abstract. The article examines an approach to the design and analysis of the organizational model of production management at an industrial enterprise based on cognitive and simulation modeling. The relevance of the study is due to the need to improve industrial enterprise management systems under conditions of high external environmental variability, increasing complexity of production and managerial relationships, and the insufficiency of static optimization models for describing the dynamics of organizational processes. The aim of the study is to formalize the organizational model of production management at a metallurgical enterprise using a causal loop diagram and to implement it subsequently in a simulation modeling environment. The research employs methods of systems analysis, economic-mathematical modeling, cognitive modeling, and system dynamics modeling. The organizational structure of the enterprise is presented as a set of production and functional subsystems interconnected through vertical and horizontal managerial interactions, while the key parameters of the model include span of control, management personnel maintenance costs, production capacity, sales volume, and net profit. The constructed cognitive map made it possible to identify the main cause-and-effect relationships among the organizational, production, and financial parameters of the enterprise, while the simulation model enabled an assessment of the impact of managerial decisions on the dynamics of costs and financial performance. The results obtained show that the use of cognitive maps in combination with simulation modeling expands the possibilities for analyzing the stability of the organizational structure and for substantiating decisions aimed at its improvement. The practical significance of the study lies in the possibility of applying the proposed approach to the design and adjustment of management systems in metallurgical and other industrial enterprises.

Keywords: cognitive modeling, cognitive map, simulation modeling, system dynamics, organizational management model, industrial enterprise, production management



Голда О.

Белорусский государственный университет информатики и радиоэлектроники (БГУИР), г. Минск, Республика Беларусь.

Кандидат экономических наук, доцент кафедры программного обеспечения информационных систем БГУИР.

Olga Golda

Belarusian State University at Informatics and Radioelectronics (BSUIR), Minsk, Republic of Belarus.

PhD in Economics, Associate Professor at the Department of Software of Information Technologies BSUIR.

E-mail: shpinyuk@gmail.com

Н. В. РУСИНА

ИНТЕГРАЦИЯ СИСТЕМНОГО ПОДХОДА К РЕШЕНИЮ ПРОБЛЕМ ПРОЦЕССА СУШКИ ЗЕРНА

Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

Аннотация. В данной статье обоснована необходимость применения системного подхода к обеспечению безопасности в процессе сушки зерна на зерносушильных комплексах и обеспечение качества зерна, а также эффективности процесса сушки. Разработана математическая модель процесса сушки, в виде системы дифференциальных уравнений, которая описывает динамику изменения температуры в процессе сушки зерна.

Ключевые слова: системный подход, системный анализ, цифровые технологии, зерносушильный комплекс, сушка зерна, математическое моделирование

Введение

Интенсивное развитие общества наряду с техническими и технологическими возможностями требует постоянного решения сложных задач в различных сферах жизни человека и необходима уверенность в том, что условия труда безопасны, а риски возникновения непредвиденных и неконтролируемых ситуаций минимальны. Так, в процессе сушки зерновых на зерносушильном комплексе имеется высокий риск возникновения аварийных ситуаций. Соблюдение температурного режима сушки важно для сохранения продовольственных и семенных качеств зерновых [1, с. 7].

Успешное решение проблемы повышения безопасности на производстве и сведение рисков опасных ситуаций к минимуму возможно с помощью системного подхода: любой объект можно представить множеством элементов (состав системы), а процесс – множеством связей или отношений, которые описывают структуру системы. При этом наличие связей превращает совокупность объектов в систему, и представляется возможность анализировать и контролировать

как каждый элемент в отдельности, так и систему в целом [2].

Цель данной работы – обоснование необходимости применения системного подхода к управлению зерносушильными комплексами и построение математической модели процесса сушки зерна. Для достижения цели необходимо решить следующие задачи: определить основные риски и нарушения, возникающие в процессе сушки зерновых; представить математическую модель процесса сушки зерна, описывающую изменение температуры слоев зерна, которую можно использовать для задания алгоритмов работы технических средств, обеспечивающих производственную безопасность и качество готового продукта.

Основная часть

Основные нарушения при сушке зерна можно разделить на следующие категории: технологические, механические, организационные. В таблице 1 представлена более подробная классификация нарушений и их последствий.

Таблица 1. Классификация, описание и последствия нарушений

Нарушение	Описание нарушения	Последствие нарушения
Превышение температуры агента сушки	Использование слишком горячего теплоносителя с целью ускорить процесс сушки	Тепловая денатурация белков, появление трещин на оболочке зерна, снижение всхожести семян
Перегрев зерна	Превышение допустимой температуры нагрева зерна	Зерно может полностью потерять пищевую ценность
Неравномерный нагрев	Возникает из-за конструктивных недостатков сушилки	В одной партии часть зерна остается сырой, а часть – пересушенной и поврежденной
Стремительный съем влаги за один подход	Попытка высушить очень влажное зерно за один цикл	Резкое снижение пропускной способности сушилки и растрескивание зерна
Конденсация влаги при охлаждении	Некорректный режим охлаждения после сушки	Повторное увлажнение уже высушенного зерна
Засорение и пылеобразование	Интенсивное трение приводит к истиранию поверхностей и образованию мелкой зерновой пыли	Высокий риск возгорания и взрыва пылевоздушной смеси, пожар в шахте, поломка оборудования, снижение качества сушки зерна

Продолжение таблицы 1

Нарушение	Описание нарушения	Последствие нарушения
Неравномерная загрузка	Зерно подается слоями с разной влажностью	Прорыв горячего воздуха мимо зерна, риск возгорания, наличие на выходе зерна различного по влажности
Нарушения при остановке зерносушилки	Остановка процесса сушки без выгрузки зерна	Зерно перегревается

Автоматические системы управления позволяют контролировать параметры сушки и мгновенно реагировать на отклонения. Использование датчиков температуры позволяет удаленно отслеживать режимы нагрева.

Системный подход для обеспечения производственной безопасности на зерносушильном комплексе предусматривает комплексное управление мерами обеспечения безопасности. Сопутствующие процессы и их краткое описание приведены в таблице 2.

Таблица 2. Интегрированное управление процессом сушки на зерносушильном комплексе

Процесс	Описание процесса
Автоматический контроль	Позволяет отслеживать все технологические параметры и информировать оператора об их состоянии
Дистанционное управление	Дистанционное управление всем технологическим оборудованием (включение, отключение, регулирование технологических параметров) осуществляется оператором посредством компьютерной системы или панели оператора
Реализация алгоритмов	Система автоматически выполняет задачи управления, контроля и сигнализации в соответствии с заданными параметрами (температура, влажность, время), оповещая о состоянии технологического процесса и авариях
Сигнализация и оповещение	Система предназначена для информирования персонала о возникновении аварийных ситуаций и отклонений от установленных (заданных) параметров
Архивирование данных	Система осуществляет запись и хранение всей информации, относящейся к динамике процесса сушки

Обобщенно любую систему можно представить следующими компонентами: вход, управляющий модуль, управляемый модуль, выход, обратная связь [3].

Входным управляемым параметром в процессе безопасной сушки зерновых является температура нагрева зерна в зерносушильном комплексе. Информация о состоянии данных параметров с помощью датчиков передается в систему управления, контроля сигнализации и архивации. Система управления на основе определенных алгоритмов анализирует информацию и формирует выходные сигналы для управления технологическим оборудованием либо устройствами сигнализации и контроля.

Техническая реализация алгоритмов управления требует использования математической модели системы. Математическая модель процесса сушки зерна может быть представлена в виде системы уравнений, которые устанавливают связь между выходными и входными данными. В описании данной математической модели в качестве оценочного показателя принята температура нагрева зерна [4].

Когда зерно находится в емкости, предназначенной для сушки, температура различна в разных частях объема. Следовательно, объект можно интерпретировать как систему с распределенными пара-

метрами. Для упрощения вычислений такую систему целесообразно разделить на элементарные части или слои. В процессе сушки тепло распространяется неравномерно и в различных слоях имеет разную температуру. Исходя из того, что поведение данной системы основывается на поведении системы в прошлом при каждом последующем шаге, для ее моделирования используем дифференциальные уравнения. Для упрощения математической модели представим разбиение всего объема зерна на два слоя 1 и 2, с температурой T_1 и T_2 соответственно, а также имеется нагреватель с температурой T_n и среда – с температурой T_{cp} .

Данную модель можно представить в виде графа:




Рисунок 1. Граф зависимости температуры нагрева зерна от времени

Из рисунка 1 видно, что температура нагревателя влияет на температуру слоя 2, которая в свою очередь влияет на температуру слоя 1, и это влияние взаимнообратное, а также температура среды влияет на температуру каждого слоя.

У разных слоев зерна разная температура, которая влияет на изменение температуры во всем объеме зерна в зерносушильной шахте. Запишем математическую модель с учетом коэффициента теплопередачи k , который характеризует интенсивность теплообмена между элементами системы в процессе сушки.

Изменение температуры с учетом k в первом слое будет иметь вид:

$$\frac{dT_1}{dt} = k_{21}(T_2 - T_1) + k_{cp1}(T_{cp} - T_1),$$

где k_{21} и k_{cp1} – коэффициенты теплопередачи, характеризующие перенос теплоты от слоя 2 к слою 1 и от среды к слою 1 соответственно.

Изменение температуры во втором слое будет иметь вид:

$$\frac{dT_2}{dt} = k_{н2}(T_{н} - T_2) + k_{12}(T_1 - T_2) + k_{cp2}(T_{cp} - T_2),$$

где $k_{н2}$, k_{12} , k_{cp2} – коэффициенты теплопередачи, характеризующие перенос теплоты от нагревателя к слою 2, от слоя 1 к слою 2 и от среды к слою 2 соответственно, $T_{н}$, T_{cp} , T_1 , T_2 – температура нагревателя, среды, слоя 1 и слоя 2 соответственно.

Процесс сушки зерна зависит от вида сельскохозяйственной культуры, типа зерносушильной установки и занимает несколько часов. В пределах суточной температуры окружающей среды можно допустить, что $T_{cp} = const$ на интервале времени, соответствующему одному циклу сушки. Температура нагревателя контролируется оператором, может меняться в режиме реального времени, задается управляющим алгоритмом и не должна превышать допустимую температурную норму для каждого вида сырья. В то же время $T_{н}$ можно считать постоянной в каждом конкретном случае.

Тогда $\frac{dT_{н}}{dt} = 0$ и $\frac{dT_{cp}}{dt} = 0$, так как $T_{н} = const$, $T_{cp} = const$.

Таким образом, вся система уравнений имеет вид:

$$\frac{dT_1}{dt} = k_{21}(T_2 - T_1) + k_{cp1}(T_{cp} - T_1);$$

$$\frac{dT_2}{dt} = k_{н2}(T_{н} - T_2) + k_{12}(T_1 - T_2) + k_{cp2}(T_{cp} - T_2);$$

$$\frac{dT_{н}}{dt} = 0; \frac{dT_{cp}}{dt} = 0.$$

Итак, получена система обыкновенных дифференциальных уравнений от одной независимой переменной времени (t). Количество тепла, которое поступает от слоя 1 к слою 2, равно количеству тепла, которое принимает слой 2 из слоя 1: $k_{12} = k_{21}$.

Для решения системы дифференциальных уравнений необходимо знать коэффициенты теплопередачи и начальное состояние системы, т. е. температуру каждого выделенного слоя, а также температуру нагревателя и среды в начальный момент времени.

Таким образом, зная, какие показатели необходимо иметь на выходе, а это зависит от того, для чего предназначено сырье (продовольствие, фураж, семенной материал), и динамику процесса сушки, согласно математическому описанию, можно задать алгоритм управления, реализуемый устройством управления, обеспечивающий точное поддержание параметров сушки. Возможность контролировать и, при необходимости, влиять на такой параметр, как температура сырья в процессе сушки, позволит оптимизировать работу зерносушилки, обеспечив ее максимальную производительность [5]. Такой подход исключит риск пересушки зерна и минимизирует угрозу возникновения аварийной ситуации в системе.

Заключение

На основании системного подхода анализа условий безопасного обеспечения процесса сушки зерновых на зерносушильном комплексе выявлены следующие необходимые обязательные меры: исправная работа оборудования; контроль технологических параметров; оперативная передача информации для реагирования персонала; обеспечение технологической и аварийной сигнализации; обучение действиям персонала в случае аварийной сигнализации. Техническая реализация безопасного процесса сушки зерновых требует алгоритмов управления на базе математической модели системы. Описана математическая модель процесса сушки зерна в зерносушилке, которая способна обеспечить оптимизацию процесса сушки, что позволяет снизить риски аварийной работы.

ЛИТЕРАТУРА

1. Шило, И. Н. Современное оборудование и машины для послеуборочной обработки зерна : справочник / И. Н. Шило, Е. И. Михайловский. Минск : БГАТУ, 2011. 508 с. URL: <https://rep.bsatu.by/handle/doc/6699> (дата обращения: 17.06.2026).
2. Белов, П. Г. Управление рисками, системный анализ и моделирование : в 3 ч. / П. Г. Белов. М.: Юрайт, 2022. Ч. 1. 211 с.
3. Системный подход в исследовании и создании пористых проницаемых материалов / П. А. Витязь, Л. П. Пилиневич, В. В. Савич, А. М. Тарайкович // Пористые проницаемые материалы: технологии и изделия на их основе : материалы 7-го Международного симпозиума (Минск, 19–20 октября 2023 г.) / редкол.: А. Ф. Ильющенко (гл. ред.) [и др.]. Минск, 2023. С. 26–35.

4. Системный подход в исследовании производственной безопасности / Л. П. Пилинович, А. Г. Бунас, Н. В. Русина // Чрезвычайные ситуации: предупреждение и ликвидация. 2025. № 1. С. 11–22. DOI: 10.54422/1994-439X.2025.1-57.11-22.

5. Тепловая обработка зерна в установках контактного типа / В. И. Курдюмов, А. А. Павлушин, Г. В. Карпенко, С. А. Сутягин. Ульяновск: УГСХА имени П.А. Столыпина, 2013. 290 с.

REFERENCES

1. Shilo I.N., Mikhaylovskiy Ye.I. *Sovremennoye oborudovaniye i mashiny dlya posleuborochnoy obrabotki zerna: spravochnik [Modern Equipment and Machines for Post-Harvest Grain Processing: Handbook]*. Minsk: BGATU; 2011. 508 p. Available at: <https://rep.bsatu.by/handle/doc/6699> (accessed 17 June 2026) (in Russian).

2. Belov P.G. *Upravleniye riskami, sistemnyy analiz i modelirovaniye [Risk Management, Systems Analysis and Modeling]*. Vol. 1. Moscow: Yurait; 2022. 211 p. (in Russian).

3. Vityaz' P.A., Pilinevich L.P., Savich V.V., Taraykovich A.M. Sistemnyi podkhod v issledovanii i sozdanii poristyykh pronitsayemykh materialov [A systematic approach to the study and creation of porous permeable materials]. *Porous Permeable Materials: Technologies and Products Thereof: Proceedings of the 7th International Symposium (Minsk, October 19–20, 2023)*. Minsk: Belaruskaya Navuka; 2023. p. 26–35. (in Russian).

4. Pilinevich L.P., Bunas A.G., Rusina N.V. Systematic approach to industrial safety research. *Emergency Situations: Prevention and Elimination*. 2025;1:11–22 (in Russian). <https://doi.org/10.54422/1994-439X.2025.1-57.11-22>.

5. Kurdyumov V.I., Pavlushin A.A., Karpenko G.V., Sutyagin S.A. *Teplovaya obrabotka zerna v ustanovkakh kontaktnogo tipa [Heat Treatment of Grain in Contact Plants]*. Ulyanovsk: UGSKHA im. P.A. Stolypina; 2013. 290 p. (in Russian).

N. V. RUSINA

INTEGRATION OF A SYSTEMIC APPROACH TO SOLVING PROBLEMS OF THE GRAIN DRYING PROCESS

*Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus*

Abstract. *In this article, the necessity of applying a systematic approach to ensuring safety in the grain drying process at grain drying complexes and ensuring grain quality, as well as the efficiency of the drying process, is justified. An analytical mathematical model of the drying process has been developed in the form of a system of differential equations that describes the dynamics of temperature change in the grain drying process.*

Keywords: *systematic approach, system analysis, digital technologies grain drying complex, grain drying, mathematical modeling*

Русина Наталья Владимировна

Белорусский государственный университет информатики и радиоэлектроники (БГУИР), г. Минск, Республика Беларусь.

Старший преподаватель кафедры «Экономическая информатика» БГУИР, аспирантка. Область научных интересов: теория системного анализа и принятия решения, системный анализ, системный подход.

Natalia Vladimirovna Rusina

Belarusian State University of Informatics and Radioelectronics (BSUIR), Minsk, Republic of Belarus.

Senior Lecturer at the Department of Economic Informatics BSUIR, Postgraduate Student. Research interests: theory of systems analysis and decision-making, systems analysis, system approach.

E-mail: n.rusina@bsuir.by

**УПРАВЛЕНИЕ
ТЕХНИЧЕСКИМИ
ОБЪЕКТАМИ**

**MANAGEMENT
OF TECHNICAL
OBJECTS**

Д. В. КАПСКИЙ, А. В. КОРЖОВА

МЕТОДОЛОГИЯ ФОРМИРОВАНИЯ ДИНАМИЧЕСКИХ МОДЕЛЕЙ МОНИТОРИНГА АТМОСФЕРНОГО ВОЗДУХА В УРБАНИЗИРОВАННЫХ ЗОНАХ НА ОСНОВЕ АЛГОРИТМОВ ОПТИМИЗАЦИИ ТРАНСПОРТНЫХ СЕНСОРНЫХ СЕТЕЙ

Белорусский национальный технический университет
г. Минск, Республика Беларусь

Аннотация. В данной научной статье представлено комплексное теоретическое и прикладное исследование, посвященное оптимизации систем мониторинга атмосферного воздуха в современных городах с населением свыше 100 тысяч человек. Актуальность работы обусловлена необходимостью перехода от традиционных пассивных статических методов наблюдения к динамическим адаптивным моделям управления качеством среды, что является ключевым элементом концепции «умного» и «симбиотического» города для минимизации экологических рисков. В качестве полигона для исследования выбраны четыре крупных промышленных и административных центра Республики Беларусь: Гродно, Пинск, Лида и Солигорск. Разработан интегрированный подход, объединяющий математическое решение задачи оптимального размещения сенсоров (SLP – Sensor Location Problem) с многофакторным графоаналитическим анализом антропогенного воздействия. Подробно описывается методология проведения 20 000 итерационных циклов для транспортной схемы, что позволило выявить критические узлы каркасных сетей городов, в которых концентрация датчиков дает минимальную погрешность вычислений транспортных и экологических параметров. Особое внимание уделено междисциплинарному учету метеорологических факторов, в частности, использованию весового коэффициента для показателей розы ветров при определении приоритетности мест установки газоанализаторов. Систематизированы данные о транспортной нагрузке, иерархии улично-дорожных сетей и плотности социальных объектов в исследуемых городах. Внедрение предложенной модели (на базе 32 автоматизированных постов) позволяет получать символичные решения для оценки экологической ситуации в неконтролируемых участках сети. Результаты исследования формируют основу для создания прогнозных систем управления выбросами, способных в реальном времени корректировать организацию дорожного движения для предотвращения превышения предельно допустимых концентраций загрязняющих веществ. В заключении очерчены перспективные направления интеграции полученных моделей с алгоритмами машинного обучения и искусственного интеллекта в рамках долгосрочных программ устойчивого городского развития.

Ключевые слова: транспортная экология, качество атмосферного воздуха, загрязняющие вещества, математическое моделирование, алгоритм SLP, роза ветров, рейтинговая оценка, интеллектуальные транспортные системы (ИТС), симбиотический город

Введение

Проблема деградации качества атмосферного воздуха в условиях стремительной урбанизации является одним из наиболее значимых вызовов для современной науки [1–4]. Транспортный комплекс, будучи мобильным источником выбросов, формирует специфическое поле загрязнения, которое крайне трудно оценить с помощью стационарных, редко расположенных постов наблюдения. В городах с населением свыше 100 тысяч человек, таких как Гродно или Пинск, транспортные потоки обеспечивают до 60–80 % общего объема выбросов оксидов азота, углерода и мелкодисперсных частиц.

Традиционный подход к мониторингу, сложившийся в XX веке, носит реактивный характер – он фиксирует уже наступившее превышение концентраций. Современное развитие городских агломераций требует пересмотра подходов к обеспечению экологической безопасности. Современная парадигма «симбиотического города» предполагает предиктивный (пред-

сказательный) подход: транспортная система должна находиться в равновесии с окружающей средой [5–8]. Согласно этой концепции, экологическая безопасность города достижима только при условии глубокой интеграции параметров транспортной инфраструктуры и систем контроля окружающей среды [9–12].

В мировой практике последних пяти лет доминирует тренд на использование Интернета вещей (IoT) и дешевых мобильных датчиков (low-cost sensors) в дополнение к высокоточным постам. Исследования ученых доказывают, что густота сенсорной сети более важна для прогнозирования острых экологических пиков, чем сверхточность отдельного прибора [11, 12].

В отечественной науке детально проработана идея «транспортной диеты» города и необходимости сопоставления «зон факельного выброса» с картами ОДД (организации дорожного движения). Также рассматриваются вопросы создания математической копии транспортного каркаса города для симуляции различных сценариев ОДД, ухода от экспертного «ручного» выбора мест установки в сторону стохастиче-

ских алгоритмов оптимизации; сочетания параметров вычислительной математики (итерации) с физико-климатическими параметрами (метеосостояния) [13–18].

Для Республики Беларусь проблема мониторинга атмосферного воздуха в городах с населением свыше 100 тыс. человек (Гродно, Пинск, Лида, Солигорск) стоит особенно остро из-за высокой концентрации промышленных объектов и плотных транспортных потоков. Традиционные методы оценки выбросов, основанные на эпизодических замерах, не дают полной картины динамического изменения концентрации загрязняющих веществ. Необходим переход к интеллектуальным транспортным системам (ИТС), где сенсоры фиксируют параметры трафика в реальном времени, позволяя строить расчетные модели загрязнения с высокой точностью. Необходимо создание динамической расчетной модели управления качеством воздуха, где первоочередной задачей является проектирование «каркаса» датчиков и сенсоров. Только научно обоснованное размещение детекторов транспортных потоков в ключевых узлах позволяет с высокой достоверностью реконструировать картину экологического состояния всей селитебной территории, минимизируя при этом затраты на избыточное количество оборудования.

Постановка задачи

Целью работы является не просто мониторинг, а моделирование сложного воздействия транспортного комплекса и стационарных источников на атмосферу. Процесс разработки базируется на создании динамической расчетной модели управления выбросами загрязняющих веществ (ЗВ) и парниковых газов. Исходными данными послужили: геометрические параметры улично-дорожной сети (УДС); схемы организации

дорожного движения (ОДД); данные о транспортной нагрузке на общегородских и местных улицах.

Важным этапом является унификация работ с алгоритмами оптимального расположения сенсоров в узлах (SLP – Sensor Location Problem). Применение единой системы ID-узлов для всех городов Беларуси позволяет создать сквозную систему аналитики государственного уровня.

Общая задача исследования заключается в разработке архитектуры системы мониторинга, состоящей из двух уровней.

Уровень 1 (транспортные датчики): программируемые сенсоры, определяющие интенсивность, скорость и состав транспортного потока.

Уровень 2 (экологические станции): приборы автоматического химического анализа воздуха.

Математическая задача (SLP): минимизировать число узлов наблюдения (N), обеспечив при этом репрезентативность данных для всей сети объемом M перекрестков с допустимой погрешностью (Δ), не превышающей пороговых значений (5–300 авт/час).

Объект исследования: каркасные сети городов Пинск, Гродно, Лида, Солигорск.

Методология и основная часть

Анализ существующего состояния

В ходе исследования был выполнен сбор данных о геометрических параметрах УДС. Транспортная нагрузка в средних городах Республики Беларусь имеет выраженную пиковую составляющую в районах расположения крупных предприятий («Гродно Азот», «Беларуськалий») и исторических центров (Пинск, Лида) (табл. 1). Разработка велась индивидуально для каждого города, учитывая специфику их транспортных каркасов.

Таблица 1. Параметры дорожного каркаса и узлов (фрагмент)

ID узла	Локализация в транспортной сети
Пинск	
216	ул. Ленина – ул. Парковая – ул. Первомайская
249	ул. Горького – ул. Завальная – ул. Иркутско-Пинской див.
309	ул. Рокоссовского
Гродно	
77	ул. Данилова – ул. Маслакова – ул. Суворова
86	бул. Ленинского Комсомола – ул. Дубко – ул. М. Горького
116	пр-т Космонавтов – пр-т Румлёвского – ул. Брикеля
143	ул. Горновых – ул. Победы – ул. Сов. Пограничников

Алгоритмическое решение задачи размещения сенсоров (SLP)

Задача нахождения приемлемого количества сенсоров заключается в достижении баланса между стоимостью оборудования и точностью данных. Эмпи-

рическим путем установлено, что 20 000 итераций достаточно для получения достоверной выборки локаций.

В Таблице 2 наглядно показано, как изменяется потребность в датчиках (сенсорах) в зависимости от заданного порога погрешности.

Таблица 2. Зависимость количества сенсоров от порога погрешности

Город	Порог интенсивности (авт/час)	Необходимое число датчиков (шт.)
Гродно	5 / 50 / 300	65 / 22 / 3
Лиды	5 / 50 / 300	16 / 10 / 2
Пинск	5 / 20 / 300	15 / 14 / 5
Солигорск	5 / 50 / 300	24 / 8 / 2

Анализ таблицы подтверждает: чем выше требования к точности (ниже порог интенсивности), тем экспоненциально больше приборов требуется для охвата каркасной сети. Для целей управления качеством атмосферы в населенных пунктах свыше 100 тыс. человек наиболее рациональным признано размещение по 8 специализированных сенсоров на каждый город.

Ниже представлено описание предложенного алгоритма D-ISEM, его математическая сущность и детальное сравнение с базовым методом.

Разработка авторского алгоритма D-ISEM (Dynamic Integrated Sensor-Environment Model) и его сравнительный анализ с базовым подходом

Базовый алгоритм базируется на методе итерационной минимизации погрешности.

- **Механизм:** проводится 20 000 итераций перебора узлов; основной критерий – нахождение такого набора узлов-доноров, который позволяет реконструировать интенсивность движения на остальных участках сети (узлах-акцепторах) с заданной погрешностью (от 5 до 300 авт/час).

- **Экологическая привязка:** выполняется после выбора транспортных узлов через аддитивную формулу рейтинга ($P=N+S+V$), где метеорологический фактор (роза ветров) учитывается как константный коэффициент ($K=2$).

Предлагаемый авторский алгоритм D-ISEM переходит от метода «перебора» к методу вероятностного энтропийного моделирования.

Математическая сущность: алгоритм минимизирует информационную энтропию (неопределенность) транспортно-экологического поля; вместо простой фиксации интенсивности, сенсор рассматривается как источник данных о «динамическом следе» загрязнения.

Ключевые этапы D-ISEM

1. Матрица связности графа (Connectivity Index): узлы оцениваются не по количеству входящих машин, а по их влиянию на общую пропускную способность каркаса (центральность по посредничеству – *Betweenness Centrality*).

2. Векторное метео-взвешивание (Dynamic Anemoi-weighting): в отличие от прототипа, роза ветров не является константой; применяется векторная функция $f(\theta)$, которая рассчитывает вероятность переноса шлейфа ЗВ от конкретного узла к ближайшим жилым кварталам в зависимости от сезонности и геометрии улиц (эффект «уличных каньонов»).

3. Критерий максимизации покрытия риска (MRCI – Multi-Risk Coverage Index): датчик устанавливается в точке, где пересекаются максимум транспортной неопределенности и максимум социального риска.

Сравнительная характеристика алгоритмов

Параметр сравнения	Базовый алгоритм	Алгоритм D-ISEM
Базовая концепция	Эмпирический итерационный подбор	Вероятностное информационное моделирование
Целевая переменная	Минимизация погрешности восстановления интенсивности (Q)	Минимизация экологической неопределенности и социального риска
Учет розы ветров	Статический коэффициент ($K=2$) для суммы баллов	Динамическая векторная функция переноса примесей в пространстве
Обработка данных	Изолированный анализ (Транспорт → Экология)	Интегрированный анализ (Транспорт ↔ Метео ↔ ПДК)
Результативность	Оптимален для фиксации средних значений трафика	Оптимален для предиктивного управления в ИТС (Smart City)
Количество итераций	Фиксированное (20 000)	Адаптивное (до достижения порога сходимости энтропии)

Обоснование преимущества авторского подхода. Использование алгоритма D-ISEM позволяет более точно локализовать датчики в условиях таких городов, как Гродно и Пинск.

- **На примере Гродно.** В то время как базовый алгоритм предлагает устанавливать датчики на магистралях с максимальным потоком (например, пр-т Космонавтов), D-ISEM смещает фокус на узлы, которые являются «критическими точками распределения». Например, пересечение ул. Данилова и ул. Соломовой получает высший приоритет не из-за рекордного числа машин, а из-за того, что при господствующем западном ветре именно здесь формируется точка бифуркации шлейфа загрязнения, накрывающего плотную социальную застройку.

- **Экономический эффект.** Алгоритм D-ISEM при сопоставимой точности позволяет использовать на 12–15 % меньше физических сенсоров за счет исключения дублирующих зон информативности, что критически важно для реализации государственных программ в условиях ограниченного бюджета.

Предложенный алгоритм базируется на фундаментальном «принципе симбиотичности» городского транспорта. Мониторинг должен служить обратной связью для управления. D-ISEM реализует этот принцип, создавая цифровую сетку, которая в будущем позволит автоматически изменять фазы регулирования

светофоров в зависимости от концентрации NOx , указанной на основе транспортных детекторов.

Решение задачи SLP (Sensor Location Problem)

Проведена серия симуляций (более 20 000 итераций). Основная трудность заключалась в том, что каркасные сети исследуемых городов имеют различ-

ную топологию: радиально-кольцевая в Гродно и прямоугольно-сеточная в Солигорске и Пинске.

В таблице 3 представлены результаты обработки информации и количество необходимых датчиков (сенсоров) в зависимости от относительной погрешности вычислений для городов Гродно, Лида, Пинск, Солигорск.

Таблица 3. Результат задачи нахождения приемлемого (оптимального) расположения сенсоров

№ п/п (№ схемы)	Наименование города	Относительная погрешность вычислений (порог интенсивности, авт/час)	Кол-во попаданий в порог интенсивности	Итого кол-во требуемых датчиков (сенсоров)
1	Гродно	5	98	65
2	Гродно	20	87	26
3	Гродно	50	69	22
4	Гродно	70	56	17
5	Гродно	100	44	26
6	Гродно	150	19	12
7	Гродно	200	7	5
8	Гродно	300	3	3
9	Лида	5	39	16
10	Лида	20	34	25
11	Лида	50	27	10
12	Лида	70	22	8
13	Лида	100	18	6
14	Лида	150	10	5
15	Лида	200	4	4
16	Лида	300	2	2
17	Пинск	5	42	15
18	Пинск	20	38	14
19	Пинск	50	34	13
20	Пинск	70	30	11
21	Пинск	100	24	9
22	Пинск	150	17	15
23	Пинск	200	13	5
24	Пинск	300	5	5
25	Солигорск	5	36	24
26	Солигорск	20	32	9
27	Солигорск	50	28	8
28	Солигорск	70	22	7
29	Солигорск	100	14	5
30	Солигорск	150	9	5
31	Солигорск	200	3	3
32	Солигорск	300	2	2

Как видно из обобщенных результатов (табл. 4), для Гродно сложность сети требует в 3–4 раза больше датчиков для достижения высокой точности, чем для Пинска. Однако в рамках реализации этапа 1 по со-

зданию базовой динамической модели, было принято унифицированное число – 8 датчиков каждого типа на город (итого 64 устройства на регион).

Таблица 4. Зависимость итогового количества датчиков от порога погрешности вычислений

Город	Порог (5 авт/час)	Порог (100 авт/час)	Порог (300 авт/час)	Рекомендовано
Гродно	65	26	3	8
Лида	16	6	2	8
Пинск	15	9	5	8
Солигорск	24	5	2	8

Анализ метеорологической компоненты

Место установки экологического датчика не может определяться только интенсивностью движения. Оно должно учитывать климатический фактор рассеивания выбросов. Роза ветров выступает как фильтр, определяющий направление переноса загряз-

нений. В отчете приводятся данные, согласно которым распределение воздушных масс существенно влияет на локализацию оборудования.

На рисунках 1–4 приведены розы ветров соответственно для городов Гродно, Лиды, Пинска, Солигорска.




Рисунок 1. Процентное распределение ветров по направлениям в г. Гродно




Рисунок 2. Процентное распределение ветров по направлениям в г. Лиде




Рисунок 3. Процентное распределение ветров по направлениям в г. Пинске




Рисунок 4. Процентное распределение ветров по направлениям в г. Солигорске

Таким образом процентное распределение ветров по направлениям

- Гродно: Юго-Запад (11.8 %), Запад (20.9 %)
- Лида: Юго-Восток (10 %), Запад (19.3 %)
- Пинск: Восток (12.7 %), Юго-Восток (11.4 %)
- Солигорск: Юг (9.3 %), Запад (22.5 %)

В Гродно доминируют западные и юго-западные ветры (20.9 % и 11.8 % соответственно), что диктует установку датчиков с подветренной стороны крупных магистралей.

Наиболее опасным с точки зрения экологии признаны западные ветры во всех исследуемых горо-

дах (средняя повторяемость выше 20 %), что требует смещения датчиков к востоку от главных осевых магистралей (ул. Данилова в Гродно, ул. Свердлова в Лиде).

Рейтинговая методика привязки экологического оборудования

Разработка схем установки газоанализаторов требует учета социально-демографических факторов. Мы использовали балльную систему (от 1 до максимального числа локаций).

Методическая формула приоритетности (P): $P = (N_{prop} + S_{obj} + V_{em}) \times K_{wind}$, где N_{prop} – рейтинг численности населения; S_{obj} – рейтинг социальных объектов (детские сады, школы, поликлиники); V_{em} – рейтинг объема выбросов ЗВ по данным экологических карт; K_{wind} – корректирующий коэффициент розы ветров (принят равным 2.0). Применение коэффициента «2» для метеорологических данных позволило сместить приоритет локаций к тем узлам, где транспортный выброс максимально эффективно переносится в селитебную зону, создавая риск для здоровья населения.

Результаты нахождения оптимального числа узлов наблюдения показывают, что предложенный алгоритм позволяет «закрыть» потребности в мониторинге города всего 32 точками контроля на четыре региона. Сравнение рейтинговых баллов для Гродно показывает, что узлы с максимальной суммой баллов (от 51 до 10) распределены неравномерно.

Установлено, что погрешность вычислений в 20 авт/час является «точкой перегиба» графика эффективности – дальнейшее снижение порога требует экспоненциального роста количества сенсоров (в Лиде – с 25 до 39, в Гродно – с 26 до 87). Это подтверждает экономическую обоснованность выбранной конфигурации сети мониторинга.

Разработка схем установки, выполненная на первом этапе, создает математические предпосылки для «символьного решения» – прогноза экологического фона на улицах, где физическая установка сенсоров невозможна из-за технических ограничений или высокой стоимости. Подобные расчетные сетки являются необходимым шагом к автоматизированному управлению светофорными объектами по экологическому критерию.

Предложенная динамическая модель управления позволяет трансформировать разрозненную информацию в структурированную систему принятия решений. В Гродно и Пинске выявлено, что 8 датчиков на город (при общем количестве наблюдаемых узлов от 15 до 65) позволяют реконструировать экологическую карту всей транспортной сети с погрешностью не более 10–15 %.

Особое значение имеет выявленная корреляция между типами загрязняющих веществ. Мониторинг

твердых частиц (PM) требует размещения сенсоров в зонах торможения и разгона (у перекрестков), в то время как оксиды азота (NO_x) более репрезентативны на скоростных перегонах. Наша методика учитывает этот «дуализм» трафика через распределение 8 приборов разного типа функционала.

Заключение

Проведенное исследование выявило, что базовый алгоритм является надежной инженерной базой для статистического учета, однако предложенный авторский алгоритм D-ISEM более пригоден для систем динамического управления, так как учитывает стохастическую природу воздушных потоков и структурную сложность транспортного графа современных белорусских городов.

Впервые реализован алгоритм SLP для нужд экологического мониторинга средних промышленных центров страны.

В рамках выполненной работы разработаны и теоретически обоснованы схемы размещения сенсорных сетей транспортного и экологического мониторинга для Гродно, Лиды, Пинска и Солигорска.

Разработана и апробирована рейтинговая методика привязки экологического оборудования, использующая метеорологический коэффициент коррекции.

Доказано, что использование алгоритма SLP в сочетании с метеорологическим коэффициентом позволяет сократить количество точек контроля на 45–60 % без потери информативности для транспортного планирования.

Установлены 32 локации для программируемых датчиков и 32 – для датчиков химического анализа, которые станут физическим носителем динамической модели управления качеством атмосферного воздуха. Таким образом определено оптимальное число точек автоматического мониторинга на исследуемый регион, что обеспечивает высокую экономическую эффективность проекта.

В рамках следующих исследований планируется реализация символьных математических решений (Interpolation of Pollutants) для покрытия всей городской застройки. Перспективным направлением является использование нейронных сетей типа LSTM (Long Short-Term Memory) для долгосрочного прогнозирования «дыхания» города на основе исторических данных за 5–10 лет. Также актуальным представляется исследование влияния автономного и электротранспорта на перераспределение весовых коэффициентов в алгоритмах SLP в условиях Республики Беларусь. Будет осуществлено решение задач оценки транспортных потоков в «темных» зонах сети, где установка физического датчика экономически нецелесообразна.

ЛИТЕРАТУРА

1. Капский, Д. В. Методология оценки воздействия изменения климата, уязвимости и климатических рисков в транспортной системе Республики Беларусь / Д. В. Капский, С. В. Богданович, Ю. В. Буртыль. Минск : БНТУ, 2022. 256 с. URL: <https://rep.bntu.by/handle/data/112369> (дата обращения: 27.04.2026).

2. Врубелъ, Ю. А. Определение потерь в дорожном движении / Ю. А. Врубелъ, Д. В. Капский, Е. Н. Кот. Минск : Белорусский национальный технический университет, 2006. 239 с. URL: <https://rep.bntu.by/handle/data/106833> (дата обращения: 27.04.2026).
3. Устойчивая городская мобильность: теория и практика развития / А. О. Лобашов, Е. Н. Кот, Д. В. Капский [и др.]. Вологда : Инфра-Инженерия, 2023. 236 с.
4. Оценка воздействия изменения климата и климатических рисков в транспортных системах / Д. В. Капский, Н. А. Филиппова, Ю. В. Трофименко [и др.]. Москва : Техполиграфцентр, 2023. 248 с.
5. Капский, Д. В. Экологические потери в дорожном движении / Д. В. Капский // Вестник ИжГТУ имени М. Т. Калашникова. 2014. № 3(63). С. 163–167. URL: <https://izdat.istu.ru/index.php/vestnik/article/view/2995> (дата обращения: 27.04.2026).
6. Капский, Д. В. Выбросы вредных веществ транспорта в симбиотическом городе и прогноз сокращения выбросов CO₂ в изменяемой транспортной системе / Д. В. Капский, Д. В. Мозалевский, И. Г. Гамульский // Проектирование автомобильных дорог : сборник докладов 80-й Международной научно-методической и научно-исследовательской конференции МАДИ, Москва, 24–28 января 2022 г. Москва, 2022. С. 244–253.
7. Капский, Д. В. Методики и модели оценки экологического воздействия автомобильного транспорта на экосистему симбиотического города / Д. В. Капский, О. В. Базаревич // Экономика Северо-Запада: проблемы и перспективы развития. 2022. № 3(70). С. 103–112. DOI: 10.52897/2411-4588-2022-3-103-112.
8. Базаревич, О. В. Использование GPS-данных для расчета экологического воздействия дорожного транспорта на экосистему симбиотических мегаполисов / О. В. Базаревич, Д. В. Капский // Системный анализ и прикладная информатика. 2022. № 4. С. 4–15. DOI: 10.21122/2309-4923-2022-4-4-15.
9. Капский, Д. В. Определение экологических потерь в населенном пункте от движения транспортных средств / Д. В. Капский, П. А. Пегин, С. А. Евтюков // Вода и экология: проблемы и решения. 2017. № 3(71). С. 147–157. DOI:10.23968/2305–3488.2017.21.3.146–157.
10. Эффективность транспортной системы симбиотического города / Д. В. Капский, В. Н. Кузьменко, Д. В. Мозалевский [и др.] // Проблемы безопасности на транспорте : материалы XI Международной научно-практической конференции, Гомель, 25–26 ноября 2021 года : в 2 ч. / редкол.: Ю. И. Кулаженко (гл. ред.) и [др.]. Гомель, 2021. Ч. 2. С. 76–77. URL: <http://elib.bsut.by/bitstream/handle/handle/123456789/6430> (дата обращения: 27.04.2026).
11. Развитие городского транспорта в городах Полоцке и Новополоцке / Д. В. Капский, А. К. Головнич, Т. В. Вигерина [др.] // Вестник Полоцкого государственного университета. Серия В, Промышленность. Прикладные науки. 2020. № 11. С. 85–97. URL: <https://journals.psu.by/industry/article/view/567> (дата обращения: 27.04.2026).
12. Оценка состояния транспортной системы городов Полоцка и Новополоцка / Д. В. Капский, В. П. Иванов, А. К. Головнич [др.] // Вестник Полоцкого государственного университета. Серия В, Промышленность. Прикладные науки. 2020. № 11. 98–102. URL: <https://journals.psu.by/industry/article/view/568> (дата обращения: 27.04.2026).
13. Guideline for air quality data collection : management approaches for clean mobility : D.T2.2.8 // Interreg Central Europe : Dynaxibility4CE. Final version 02 2022. URL: <https://programme2014-20.interreg-central.eu/Content.Node/Dynaxibility4CE/D.T2.2.8-arpa-final-version.pdf> (дата обращения: 27.04.2026).
14. Mobile monitoring of air pollution – a position paper on use cases, good practices, challenges, and opportunities / J. Kerckhoffs, J. Hofman, J. Khan [et al.] // Environment International. 2025. Vol. 202. 109582. DOI: 10.1016/j.envint.2025.109582.
15. Air quality monitoring in coal-centric cities: a hybrid approach / S. Mora, P. deSouza, F. Duarte [et al.] // Sustainability. 2023. Vol. 15, № 16. 12624. DOI: 10.3390/su151612624.
16. Big mobility data reveals hyperlocal air pollution exposure disparities in the Bronx, New York / I. Testi, A. Wang, S. Paul [et al.] // Nature Cities. 2024. №1. С. 512–521. DOI: 10.1038/s44284-024-00093-x.
17. Air quality monitoring using mobile low-cost sensors mounted on trash-trucks: methods development and lessons learned / P. DeSouza, A. Anjomshoa, F. Duarte [et al.] // Sustainable Cities and Society. 2020. Vol. 60. 102239. DOI: 10.1016/j.scs.2020.102239.
18. Air pollution and greenspace exposure disparities revealed by hyperlocal exposure metrics across European cities / M. E. S. Sabedotti, F. Duarte, P. Koutrakis [et al.] // Communications Sustainability. 2026. Vol. 1, № 48. P. 1–14. DOI: 10.1038/s44458-026-00046-6.

REFERENCES

1. Kapski D.V., Bogdanovich S.V., Burtyl' Ju.V. *Metodologija ocenki vozdeystviya izmenenija klimata, uязvimo-sti i klimaticheskikh riskov v transportnoj sisteme Respubliki Belarus' [Methodology for Assessing the Impact of Climate Change, Vulnerability and Climate Risks in the Transport System of the Republic of Belarus]*. Minsk: BNTU; 2022. 256 p. (in Russian). Available at: <https://rep.bntu.by/handle/data/112369> (accessed 27 April 2026).
2. Vrubel' Ju.A., Kapski D.V., Kot E.N. *Opredelenie poter' v dorozhnom dvizhenii [Determination of Traffic*

Losses]. Minsk: BNTU; 2006. 239 p. (in Russian). Available at: <https://rep.bntu.by/handle/data/106833> (accessed 27 April 2026).

3. Lobashov A.O., Kot E.N., Kapski D.V., Larin O.N., Bogdanovich S.V., Semchenko S.S. *Ustojchivaya gorodskaya mobil'nost': teoriya i praktika razvitiya [Sustainable Urban Mobility: Theory and Practice of Development]* Vologda: Infra-Inzhenerija; 2023. 236 p. (in Russian).

4. Kapski D.V., Filippova N.A., Trofimenko Ju.V., et al. *Ocenka vozdeystviya izmenenija klimata i klimaticheskikh riskov v transportnykh sistemakh [Assessing the Impacts of Climate Change and Climate Risks in Transport Systems]*. Moscow: Tehpoligrafcentr; 2023. 248 p. (in Russian).

5. Kapski D.V. Ekologicheskie poteri v dorozhnom dvizhenii [Environmental losses in road traffic]. *Vestnik IzheGTU imeni M. T. Kalashnikova [Vestnik of Kalashnikov Izhevsk State Technical University]*. 2014;3(63):163–167 (in Russian). Available at: <https://izdat.istu.ru/index.php/vestnik/article/view/2995> (accessed 27 April 2026).

6. Kapski D.V., Mozalevskij D.V., Gamulskij I.G. Vybrosy vrednykh veshchestv transporta v simbioticheskom gorode i prognoz sokrashcheniya vybrosov CO₂ v izmenyaemoj transportnoj sisteme [Emissions of harmful substances of transport in a symbiotic city and forecast of CO₂ emission reduction in a modified transport system]. *Proektirovanie avtomobil'nykh dorog : sbornik dokladov 80-j Mezhdunarodnoj nauchno-metodicheskoy i nauchno-issledovatel'skoj konferencii MADI [Designing Highways: Collection of Reports of the 80th International Scientific, Methodological and Research Conference of MADI]*, Moscow, January 24–28, 2022. Moscow; 2022. pp 244–253 (in Russian).

7. Kapski D.V., Bazarevich O.V. Methods and models for assessing the environmental impact of road transport on the ecosystem of a symbiotic city. *Ehkonomika Severo-Zapada: problemy i perspektivy razvitiya [Economy of the North-West: Problems and Prospects for Development]*. 2022;3(70):103–112 (in Russian). <https://doi.org/10.52897/2411-4588-2022-3-103-112>.

8. Bazarevich O.V., Kapski D.V. Using GPS data to calculate the ecological impact of road transport on the ecosystem of symbiotic megacities. *System Analysis and Applied Information Science*. 2022;(4):4–15 (in Russian). <https://doi.org/10.21122/2309-4923-2022-4-4-15>.

9. Kapskiy D.V., Pegin P.A., Evtyukov S.A. Definition of ecological losses in the city from the movement of vehicles. *Voda i ehkologiya: problemy i resheniya [Water and Ecology: Problems and Solutions]*. 2017;(71):147–157 (in Russian). <https://doi.org/10.23968/2305-3488.2017.21.3.147-158>.

10. Kapski D.V., Kuzmenko V.N., D. V. Mozalevskij D.V., Krasilnikova A.S., Karaseva M.G. Effektivnost' transportnoj sistemy simbioticheskogo goroda [Efficiency of the transport system of the symbiotic city]. *Problemy bezopasnosti na transporte : materialy XI Mezhdunarodnoj nauchno-prakticheskoy konferencii [Problems of Transport Safety: Materials of the XI International Scientific and Practical Conference]*, Gomel, November 25–26, 2021. Volume 2. Gomel; 2021. pp. 76–77 (in Russian). Available at: <http://elib.bsut.by/bitstream/handle/handle/123456789/6430> (accessed 27 April 2026).

11. Kapskiy D., Golovnich A., Vigerina T., Kuzmenko V., Krasilnikova A., Gorelik Ye, et al. Development of urban transport in the cities of Polotsk and Novopolotsk. *Vestnik Polockogo gosudarstvennogo universiteta. Seriya B. Promyshlennost'. Prikladnye nauki [Vestnik of Polotsk State University. Series B. Industry. Applied Sciences]*. 2020;11:85–97 (in Russian). Available at: <https://journals.psu.by/industry/article/view/567> (accessed 27 April 2026).

12. Kapskiy D., Ivanov V., Golovnich A., Kuzmenko V., Krasilnikova A., Gorelik Ye., et al. Assessment of the condition of the transport system of the cities of Polotsk and Novopolotsk. *Vestnik Polockogo gosudarstvennogo universiteta. Seriya B. Promyshlennost'. Prikladnye nauki [Vestnik of Polotsk State University. Series B. Industry. Applied Sciences]*. 2020;11:98–102 (in Russian). Available at: <https://journals.psu.by/industry/article/view/568> (accessed 27 April 2026).

13. Guideline for air quality data collection: Management approaches for clean mobility (D.T2.2.8). *Interreg Central Europe: Dynaxibility4CE*; 2022 Feb. Available at: <https://programme2014-20.interreg-central.eu/Content.Node/Dynaxibility4CE/D.T2.2.8-arpae-final-version.pdf> (accessed 27 April 2026).

14. Kerckhoffs J., Hofman J., Khan J., Adams M.D., Blanco M.N., deSouza P., et al. Mobile monitoring of air pollution – a position paper on use cases, good practices, challenges, and opportunities. *Environment International*. 2025;202:109582. <https://doi.org/10.1016/j.envint.2025.109582>.

15. Mora S., deSouza P., Duarte F., Wang A., Paul S., Berrones A., et al. Air quality monitoring in coal-centric cities: A hybrid approach. *Sustainability*. 2023;15(16):12624. <https://doi.org/10.3390/su151612624>.

16. Testi I., Wang A., Paul S., Mora S., Walker E., Marguerite N., et al. Big mobility data reveals hyperlocal air pollution exposure disparities in the Bronx, New York. *Nature Cities*. 2024;1:512–521. <https://doi.org/10.1038/s44284-024-00093-x>.

17. DeSouza P., Anjomshoa A., Duarte F., Kahn R., Kumar P., Ratti. Air quality monitoring using mobile low-cost sensors mounted on trash-trucks: Methods development and lessons learned. *Sustainable Cities and Society*. 2020;60:102239. <https://doi.org/10.1016/j.scs.2020.102239>.

18. Sabedotti M.E.S., Duarte F., Koutrakis P., Santi P., Ratti C., Nyhan M.M. Air pollution and greenspace exposure disparities revealed by hyperlocal exposure metrics across European cities. *Communications Sustainability*. 2026;1:48. <https://doi.org/10.1038/s44458-026-00046-6>.

D. V. KAPSKI, A. V. KORZHOVA

METHODOLOGY OF FORMING DYNAMIC AIR QUALITY MONITORING MODELS IN URBAN AREAS BASED ON TRAFFIC SENSOR NETWORK OPTIMIZATION ALGORITHMS

Belarusian National Technical University
Minsk, Republic of Belarus

Abstract. This scientific article presents a comprehensive theoretical and applied study dedicated to the optimization of atmospheric air monitoring systems in modern cities with populations over 100,000. The relevance of this study stems from the need to transition from traditional passive static monitoring methods to dynamic adaptive models of environmental quality management, a key element of the "smart" and "symbiotic" city concept for minimizing environmental risks. Four major industrial and administrative centers of the Republic of Belarus – Grodno, Pinsk, Lida, and Soligorsk – were selected as the research sites. The scientific novelty of this study lies in the development of an integrated approach combining a mathematical solution to the optimal sensor placement problem (SLP) with a multivariate graphical analysis of anthropogenic impact. A detailed methodology is provided for conducting 20,000 iteration cycles for each transport scheme, which made it possible to identify critical nodes in urban framework networks where the concentration of sensors provides minimal error in calculating transport and environmental parameters. Particular attention is paid to the interdisciplinary consideration of meteorological factors, in particular, the use of a weighting factor for wind rose indicators when prioritizing gas analyzer installation locations. The article systematizes data on traffic load, the hierarchy of street and road networks, and the density of social facilities in the studied cities. Implementation of the proposed model (based on 32 automated posts) allows for the generation of symbolic solutions for assessing the environmental situation in unmonitored network sections. The study's results form the basis for the development of predictive emission management systems capable of adjusting traffic management in real time to prevent exceeding maximum permissible pollutant concentrations. The conclusion outlines promising areas for integrating the resulting models with machine learning and artificial intelligence algorithms within the framework of long-term sustainable urban development programs.

Keywords: transport ecology, air quality, pollutants, mathematical modeling, SLP algorithm, wind rose, rating assessment, intelligent transport systems (ITS), symbiotic city



Капский Денис Васильевич

Белорусский национальный технический университет, г. Минск, Республика Беларусь.
Доктор технических наук, профессор. Профессор кафедры «Транспортные системы и технологии».

Высшая аттестационная комиссия (ВАК) Республики Беларусь, заместитель Председателя ВАК.

Проводит исследования в области организации движения, технических средств регулирования и информационно-алгоритмического обеспечения управления движением, транспортного планирования и математического моделирования процессов транспортных систем.

Denis V. Kapski

Belarusian National Technical University, Minsk, Republic of Belarus.

Doctor of Science (Engineering), Professor. Professor of the Department of Transport Systems and Technologies.

Vice-chairman of the Higher Attestation Commission (HAC) of the Republic of Belarus.

Conducts research in the field of traffic management, technical means of regulation and information and algorithmic support for traffic control, transport planning and mathematical modeling of transport systems processes.

E-mail: d.kapsky@bntu.by



Коржова Антонина Владимировна

Филиал Белорусского национального технического университета «Научно-исследовательский политехнический институт», г. Минск, Республика Беларусь.

Магистр технических наук, заведующая сектором дорожного движения НИИЦТС. Проводит исследования в области организации движения и технических средств регулирования.

Antonina V. Korzhova

Research Polytechnic Institute (Belarusian National Technical University branch), Minsk, Republic of Belarus.

Master of Engineering. Head of the Traffic Sector at the Research and Testing Center for Vehicles. Conducts research in the field of traffic organization and technical control means.

E-mail: nicdd@bntu.by

А. А. ЛОБАТЫЙ¹⁾, Ю. И. СЕМАК²⁾, Л. Н. ГОТИНА¹⁾

СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПРИ АВТОМАТИЗИРОВАННОМ УПРАВЛЕНИИ

¹⁾ Белорусский национальный технический университет
г. Минск, Республика Беларусь

²⁾ Научно-производственный центр многофункциональных беспилотных комплексов
Национальной академии наук Беларуси
г. Минск, Республика Беларусь

Аннотация. Рассмотрены общие принципы построения системы поддержки принятия решений при управлении беспилотным летательным аппаратом (БЛА) с наземного пункта управления на основе измерений и оценки технического состояния бортовых систем БЛА. Проведен анализ современных методов решения таких задач, обосновано использование алгоритмических методов решения, основанных на использовании стохастических математических моделей процессов изменения переменных, характеризующих техническое состояние БЛА. Приведены дифференциальные уравнения общего вида, описывающие эволюцию рассматриваемой системы, полученные на основе применения теории систем со случайным изменением структуры. Приведена блок-схема, характеризующая общие принципы решения задачи вероятностной оценки технического состояния системы, на основе которой получен дискретный алгоритм решения задачи оптимальной фильтрации и идентификации режима работы с управлением процесса наблюдения. Приведен пример решения задачи для простейших математических моделей процесса изменения технического параметра и его измерителя, наглядно демонстрирующий работоспособность предложенного алгоритма.

Ключевые слова: беспилотный летательный аппарат, техническое состояние, вероятность, структура, фильтрация, идентификация

Введение

Развитие электронных и информационных технологий приводит к появлению новых возможностей и задач при управлении сложными техническими объектами. К таким объектам относятся беспилотные летательные аппараты (БЛА), которые широко используются как в гражданской, так и в военной сферах [1, 2]. Одна из задач успешного применения БЛА – обеспечение их технической надежности в полете.

Известно, что БЛА способен работать, как в автоматическом, так и в автоматизированном режимах. Главной его особенностью является интерактивное управление. В силу высокой стоимости, ограниченного доступа к бортовым системам и сложности эксплуатации беспилотного авиационного комплекса (БАК) возникла острая практическая потребность непрерывного (оперативного) контроля технического состояния БЛА, находящегося в полете. Кроме того, иногда в процессе выполнения задания возникает необходимость корректировки параметров полета БЛА и/или режимов работы его систем. Решение данных задач обусловило необходимость установки на борт БЛА новых систем, позволяющих получать и регистрировать объемное потребное количество информации и даже представляющих данные в формате «видео» [3].

Рациональным решением данной задачи является не просто «освобождение» оператора БЛА от контроля технического состояния оборудования БЛА в полете и введение для этого в состав наземного пункта управле-

ния (НПУ) автоматизированного рабочего места (АРМ) инженера БЛА, но главным образом – автоматизация управления оборудованием в полете в особых случаях (при отказах, повреждениях, сбоях бортовых систем).

Автоматизация управления оборудованием может быть осуществлена введением (повышением) бортового «интеллекта» БЛА и наземного «интеллекта» НПУ путем применения технологий «искусственного интеллекта» – создания определенных специализированных бортовых и наземных устройств с «искусственным интеллектом», которые не только решают задачу контроля технического состояния оборудования БЛА, но и формируют рекомендации для инженера БЛА по принятию решений об управлении режимами работы бортовых систем при возникновении отказов в полете. Такой системой является аппаратно-программный комплекс (АПК) оперативного контроля технического состояния БЛА в полете, а его реализацией – соответствующий комплекс АРМ инженера БЛА, виртуальный имитатор работы БАК, интеллектуальное бортовое устройство контроля, специальное программное обеспечение, а также рабочая конструкторская документация, технологическая и программная документация на АПК [2, 3].

Контроль технического состояния БЛА

Типичным представителем БЛА многоцелевого назначения является беспилотный авиационный комплекс (БАК) «Бусел» [4]. На рис. 1 представлен внешний вид наземного пункта управления комплексом «Бусел».

Автоматизированное рабочее место инженера БЛА (рис. 1) предназначено для непрерывного контроля работы основных систем и бортового оборудования БЛА в полете, а также для информационной поддержки принятия решений расчетом БАК по результатам контроля в случае нештатных ситуаций в полете. В основе функционирования АРМ инженера БЛА лежит оценка работоспособности бортовых систем и компонентов БЛА, оснащенных автономной системой управления с искусственным интеллектом на базе микроконтроллеров («нейромодулей») и специального программного обеспечения.



Рисунок 1. Внешний вид наземного пункта управления

Ключевой составляющей элементов системы управления БАК и его техническим состоянием является система поддержки принятия решений (СППР), предоставляющая в процессе функционирования БЛА инженеру информацию о техническом состоянии подсистем БЛА с вероятностной оценкой возможных нежелательных ситуаций (отказов элементов системы).

Одним из путей реализации СППР БАК является создание виртуального имитатора работы БАК в виде «искусственного интеллекта» на основе нейронных сетей, реализованных в цифровом виде. Виртуальный имитатор работы БАК предназначен для «обучения» нейронных сетей в ходе работ по созданию систем бортового «интеллекта» БЛА и наземного «интеллекта» НПУ, а также – для тренировки расчета БАК. Данный имитатор позволит реализовывать различные сценарии ситуационной осведомленности расчета БАК. Бортовое устройство контроля за техническим состоянием на основе «нейромодулей» предназначено для контроля бортового оборудования БЛА и в случае необходимости – принятия решений на реконфигурацию бортовых систем для минимизации последствий возникшей в полете нештатной ситуации (отказа).

«Обучение» такой нейронной сети требует большого объема априорной информации о всех возможных вариантах изменения параметров, определяющих техническое состояние БЛА, что практически реализовать очень трудно. «Обученная» таким образом нейронная сеть, тем не менее, не в состоянии предусмотреть всех возможных ситуаций, в которых может находиться БЛА в процессе полета, что не обеспечит необходимые требования к СППР.

В то же время параметры, характеризующие техническое состояние БЛА, подчиняются известным законам физики (механика, электроника и т.д.) и имеют свои апробированные математические модели. Измерение этих параметров производится датчиками, для которых также имеются свои математические модели.

Математическая модель технического состояния БЛА

В общем случае процессы, характеризующие состояние БАК как сложной мехатронной системы являются случайными и описываются векторным стохастическим уравнением вида [5]:

$$\begin{aligned}\dot{X}(t) &= D(t)\varphi(X, t) + W(X, t)U(t) + H(X, t)\xi(t), \\ X(t_0) &= X_0,\end{aligned}\quad (1)$$

где $X(t)$ – n -мерный случайный вектор (матрица-столбец); $D(t)$ – матрица порядка $n \times n$ детерминированных параметров с компонентами d_{kr} ; $\varphi(x, t)$ – векторная; $W(x, t)$, $H(x, t)$ – матричные нелинейные функции; $U(t)$ – r -мерная ($r \leq n$) векторная функция управления; $\xi(t)$ – n -мерный вектор центрированного гауссова белого шума с положительно-определенной матрицей интенсивностей $G(t)$ и матрицей корреляционных функций $K_\xi(t, t') = G(t)\delta(t - t')$, $\delta(\dots)$ – дельта-функция Дирака.

При случайном скачкообразном изменении режимов работы системы управления БЛА (отказах подсистем) изменяется вид (структура s [5, 6]) уравнения состояния (1). В данном случае s – номер состояния, в котором может находиться система – случайная дискретная последовательность. Математическая модель измерителей с учетом известных обоснованных допущений имеет вид:

$$Z^{(s)}(t) = C^{(s)}X^{(s)}(t) + \zeta(t), \quad (s = \overline{1, ns}), \quad (2)$$

где $Z^{(s)}(t)$ – m -мерный вектор, $C^{(s)}(X^{(s)}, t)$ – нелинейная векторная функция, $\zeta(t)$ – m -мерный белый гауссовый шум с матрицей интенсивностей $Q(t)$. При небелом шуме $\zeta(t)$ или инерционном измерителе модель измерителя сводится к виду (2) путем расширения вектора состояния.

Полной вероятностной характеристикой вектора $[X(t), S(t)]^T$ в момент времени t при наличии измерений вектора $Z^{(s)}(t)$ в интервале $[t_0, t]$ является апостериорная функция плотности вероятности $\hat{f}^{(s)}(x, t)$, для которой справедливо обобщенное (для систем случайной структуры) уравнение Стратоновича [5]:

$$\begin{aligned}\frac{\partial \hat{f}^{(s)}(x, t)}{\partial t} &= -\text{div} \hat{\pi}^{(s)}(x, t) - \\ &- \sum_{r=1}^{ns} \sum_{(r \neq s)} [\hat{y}_{sr}(x, t) - \hat{u}_{rs}(x, t)] - \frac{1}{2} [\rho(x, z, t) - \\ &- \sum_{k=1}^{ns} \int_{-\infty}^{\infty} \rho(x, z, t) \hat{f}^{(k)}(x, t) dx] \cdot \hat{f}^{(s)}(x, t)\end{aligned}\quad (3)$$

при начальных условиях $\hat{f}^{(s)}(x, t_0) = f(x, t_0)$. $\hat{\pi}^{(s)}(x, t)$ – вектор апостериорной плотности потока вероятности s -й структуры с компонентами по фазовым координатам, вычисляемым по формуле:

$$\hat{\pi}_k^{(s)}(x, t) = A_k^{(s)} x(t) \hat{f}_k^{(s)}(x, t) - \frac{1}{2} \sum_{v=1}^{ns} B_{kv}^{(s)}(x, t) \hat{f}_k^{(s)}(x, t), \quad (k = \overline{1, ns}). \quad (4)$$

$A_k^{(s)}$ и $B_{kv}^{(s)}$ – компоненты вектора сноса и матрицы диффузии. $\rho(x, z, t)$ – функция невязки, которая при допущении о нормальности процесса $\zeta(t)$ в общем случае определяется выражением:

$$\rho(x, z, t) = \sum_{p,v=1}^m \rho_{pv}(x, z, t), \quad \rho_{pv}(x, z, t) = \frac{\bar{Q}_{p,v}(t)}{|Q(t)|} [z_p - C_p(t)x][z_p - C_p(t)x]. \quad (5)$$

$\bar{Q}_{pv}(t)$ – алгебраическое дополнение элемента $Q_{pv}(t)$ в определителе $|Q(t)|$ матрицы $Q(t)$ белых шумов $\zeta(t)$ измерителя.

В выражении (3) $\hat{v}_{sr}$ – оценка интенсивности перехода реализаций процесса $X(t)$ из области s в область r (интенсивность поглощения реализаций структуры s). $\hat{u}_{rs}(x, t)$ – оценка интенсивности возврата реализаций процесса $X(t)$ из области r в область s (интенсивность восстановления реализаций структуры s).

Проинтегрировав уравнение (3) по x в бесконечных пределах, получается дифференциальное уравнение для апостериорной вероятности состояния $\hat{P}_s(s = \overline{1, ns})$ (s -го режима) [7].

При гауссовой аппроксимации функции $\hat{f}^{(s)}(x, t)$ векторно-матричное уравнение для апостериорных математических ожиданий $\hat{X}^{(s)}(t)$ (оценок вектора $X(t)$) и апостериорных корреляционных моментов $\hat{R}^{(s)}(t)$ получаются в соответствии с известными положениями теории вероятностей умножением уравнения (3) соответственно на $X^{(s)}(t)$ или $(X^{(s)}(t) - \hat{X}^{(s)}(t))^2$ и интегрированием в бесконечных пределах [8].

Оценка состояния БЛА в условиях многорежимности

На практике основные измерения и обработка информации в системе управления БЛА производятся в дискретной форме. Следовательно, математические модели процесса $X_k = X(t_k)$ и измерителя $Z_k = Z(t_k)$ при этом имеют вид разностных уравнений. Пусть функционирование стохастической системы управления описывается векторно-матричным уравнением вида [5, 6]:

$$X_k = A_{k-1,k} X_{k-1} + L_{k-1,k} U_{k-1} + H_{k-1,k} \xi_{k-1}, \quad (6)$$

где X_k – n -мерный вектор состояния системы на k -м шаге; $A_{k-1,k}$, $L_{k-1,k}$, $H_{k-1,k}$ – матрицы перехода размерности $n \times n$; U_{k-1} – n -мерный вектор управления на $(k-1)$ -м шаге; ξ_{k-1} – вектор дискретного гауссова белого шума интенсивности G_ξ .

Измерения также производятся в дискретные моменты времени, а работа измерителя описывается уравнением:

$$Z_k^{(s)} = C_k^{(s)} X_k + \zeta_k, \quad (7)$$

где $Z_k^{(s)}$ – m -мерный вектор измерений на k -м шаге; $C_k^{(s)}$ – матрица коэффициентов на k -м шаге; ζ_k – дискретный белый шум измерений интенсивности G_ξ . $s = \overline{1, ns}$ – номер режима (структуры) системы, ns – число возможных структур системы.

Алгоритм оценивания фазовых координат (вектора X_k) для линейных дискретных моделей (6)–(7) процесса и измерителя s -го режима представляет собой известные выражения для фильтра Калмана [8, 9]:

$$\left. \begin{aligned} \tilde{X}_k^{(s)} &= A_{k-1,k}^{(s)} X_{k-1}^{(s)} + L_{k-1,k}^{(s)} U_{k-1}, \\ \hat{X}_k^{(s)} &= \tilde{X}_k^{(s)} + B_k^{(s)} [Z_k - C_k^{(s)} \tilde{X}_k^{(s)} - K_k^{(s)} U_k], \\ B_k^{(s)} &= \tilde{R}_k^{(s)} C_k^{(s)T} [C_k^{(s)} \tilde{R}_k^{(s)} C_k^{(s)T} + Q_k]^{-1}, \\ \tilde{R}_k^{(s)} &= A_{k-1,k}^{(s)} R_{k-1}^{(s)} A_{k-1,k}^{(s)T} + H_{k-1,k}^{(s)} G_k^{(s)} H_{k-1,k}^{(s)T}, \\ R_k^{(s)} &= (E - B_k^{(s)} C_k^{(s)}) \tilde{R}_{k-1}^{(s)}, \end{aligned} \right\} \quad (8)$$

где $\tilde{X}_k^{(s)}$, $\hat{X}_k^{(s)}$ – априорная и апостериорная оценки вектора состояния системы управления БЛА на k -м шаге; $\tilde{R}_k^{(s)}$, $R_k^{(s)}$ – априорная и апостериорная ковариационные матрицы ошибок оценивания; E – единичная матрица.

Для определения вероятности s -го режима в дискретной задаче удобно использовать байесовский алгоритм определения апостериорной вероятности состояния системы [6] при допущении о том, что на интервале дискретизации смена режима практически невозможна (маловероятна) и априорная вероятность на k -м шаге равна апостериорной вероятности на предыдущем шаге [9].

$$\hat{P}_k^{(s)} = \frac{\bar{P}_k^{(s)} |\bar{D}_k^{(s)}|^{-\frac{1}{2}} \exp[-\tilde{h}^{(s)}(Z_k, \tilde{X}_k^{(s)}, \tilde{R}_k^{(s)})]}{\sum_{i=1}^{nl-1} \bar{P}_k^{(i)} |\bar{D}_k^{(i)}|^{-\frac{1}{2}} \exp[-\tilde{h}^{(i)}(Z_k, \tilde{X}_k^{(i)}, \tilde{R}_k^{(i)})]}, \quad (9)$$

где $\bar{P}_k^{(s)} = \bar{P}_{k-1}^{(s)}$, $\bar{D}_k^{(s)} = C_k^{(s)} \tilde{R}_k^{(s)} C_k^{(s)T} + Q_k^{(s)}$, $\tilde{h}^{(s)}(Z_k, \tilde{X}_k^{(s)}, \tilde{R}_k^{(s)}) = \frac{1}{2} (Z_k - C_k^{(s)} \tilde{X}_k^{(s)} - K_k^{(s)} U_k)^T (\bar{D}_k^{(s)})^{-1} (Z_k - C_k^{(s)} \tilde{X}_k^{(s)} - K_k^{(s)} U_k)$. $\bar{P}_k^{(s)}$ и $\bar{P}_{k-1}^{(s)}$ – априорная и апостериорная вероятности s -го режима на k -м шаге. вероятность s -го режима определяется из условия нормировки:

$$\hat{P}^{(s)} = 1 - \sum_{l=1}^{nl-1} \hat{P}^{(l)}. \quad (10)$$

Таким образом, согласно критерию Байеса проверяемая система с наибольшей вероятностью находится в состоянии, соответствующем K -му режиму,

апостериорная вероятность которого превышает апостериорные вероятности остальных режимов: $\hat{s} = K$ при $\hat{P}^{(k)} = \max\{P_1, \dots, P_{ns}\}$, $s, \hat{s} = \overline{1, ns}$.

Решая совместно уравнения (8)–(10) можно определить, в каком режиме находится система, и оценить вектор ее фазовых координат (провести фильтрацию сигналов, необходимых для определения технического состояния параметров БЛА).

Если в системе производится комплексирование индикаторов состояния и измерителей параметров, то в результате оптимальной обработки информации определяется совместный закон распределения фазовых координат и структуры (режима), на основании которого могут быть найдены оптимальные оценки фазовых координат и индекса структуры (режима работы) системы (рис. 2) [6].




Рисунок 2. Блок-схема комплексной системы наблюдения состояния

На рис. 2 $Z(t)$ – вектор выходных сигналов измерителя (измерителей), $r(t)$ – дискретный выходной сигнал индикатора, $\eta(t)$ и $\xi(t)$ – случайные помехи (стационарные неопределенности). Из рисунка видно,

что индикатор и измеритель связаны между собой через выходные сигналы, так как показания индикатора зависят от фазовых координат $X(t)$, а показания измерителя зависят от режима работы $S(t)$.

Существует большое число практических задач, когда наличие обратной связи в канале наблюдения задается априорно. Это приводит к тому, что свойства канала наблюдения становятся зависимыми от процессов, протекающих в фильтре. В подобных случаях задача оптимальной фильтрации измеряемых фазовых координат системы (эксплуатационных параметров БАК) обладает специфическими особенностями. Свойства канала наблюдения могут изменяться под влиянием управляющего воздействия $U(t)$, которое формируется таким образом, чтобы обеспечить наилучшие условия фильтрации измеренного параметра. Такая постановка относится к комбинированным задачам, когда в процессе фильтрации необходимо одновременно вести управление свойствами канала наблюдения.

Пример

Рассмотрим для наглядности простейший случай одномерной системы, когда один из параметров, характеризующих техническое состояние, описывается выражением (6), а его измерение описывается выражением (7), при этом возможны два режима работы рассматриваемого устройства (исправное и неисправное), смена которых происходит случайным образом. В первом режиме ($s=1$) параметры системы (6)–(7) следующие: $A^{(1)}=1$, $L^{(1)}=-0.005$, $U^{(1)}=-4$, $G^{(1)}=3$, $C^{(1)}=1$, $H^{(1)}=1$, $Q^{(1)}=0.4$. Во втором режиме ($s=2$): $A^{(2)}=1$, $L^{(2)}=0.005$, $U^{(2)}=-3$, $G^{(2)}=1.5$, $C^{(2)}=1$, $H^{(2)}=1$, $Q^{(2)}=2$.

На рис. 3 представлены графики изменения сигналов на выходе измерителя: для первого режима $Z_k^{(1)}=z1_k$ и для второго режима $Z_k^{(2)}=z2_k$ системы. Моделирование производилось в среде Mathcad.




Рисунок 3. Процессы $Z_k^{(1)}$ и $Z_k^{(2)}$ на выходе измерителей

На рис. 4 приведены временные зависимости апостериорных вероятностей каждого из возможных режимов системы $\hat{P}^{(1)} = P1_k$ и $\hat{P}^{(2)} = P2_k$.

В алгоритме распознавания априорные вероятности структур задавались равными $P_1 = P_2 = 0.5$.




Рисунок 4. Вероятности возможных режимов системы

Заключение

Анализ результатов моделирования показал, что предлагаемые алгоритмы фильтрации и идентификации режимов работы системы позволяют с высокой степенью достоверности определить режим (структуру), в котором находится система. Время, необходимое для оценки структуры системы, в данном примере составило менее одной секунды. При этом количество режимов идентифицируемых с помощью рассматриваемого

алгоритма практически не ограничено и зависит от адекватности математических моделей системы, находящейся в том или ином режиме работы.

Применение в комплексе СППР БАК алгоритмов идентификации режима в дополнение к калмановским алгоритмам фильтрации ошибок измерителей позволяет повысить устойчивость БАК к внезапным изменениям режимов работы, что повысит эффективность применения БЛА, которые являются сложными и дорогостоящими комплексами.

ЛИТЕРАТУРА

1. Беспилотные летательные аппараты : справочник / сост.: В. Ю. Барковский, Л. Р. Милованова ; под ред. Н. Н. Новичкова. Москва: АРМС-ТАСС, 2009. 436 с.
2. Эксплуатация и применение беспилотных летательных аппаратов (FPV-дронов) : учебное пособие / А. В. Ананьев, М. А. Булгаков, М. Ф. Волобуев [и др.]. Воронеж : ВУНЦ ВВС «ВВА», 2023 г. 235 с.
3. Семак, Ю. И. Аппаратно-программный комплекс оперативного контроля технического состояния БЛА в полете / Актуальные вопросы науки и техники в сфере развития авиации : материалы XV Международной научно-практической конференции / Военная академия Республики Беларусь. Минск, 2025. С. 81.
4. Семейство беспилотных летательных аппаратов «Бусел», «Бусел М» и «Бусел М50» для мониторинга местности // Республиканский центр трансфера технологий. URL: <https://www.ictt.by/rus/exh/plan/view.php?proid=cdd3ad7eb0cc77d4f3849f6873ce3c&lng=eng> (дата обращения: 27.04.2026).
5. Казаков, И. Е. Анализ систем случайной структуры / И. Е. Казаков, В. М. Артемьев, В. А. Бухалев. Москва : Наука, 1993. 270 с.
6. Бухалев, В. А. Распознавание, оценивание, и управление в системах со случайной скачкообразной структурой / В. А. Бухалев. Москва : Наука, 1996. 286 с.
7. Бухалев, В. А. Алгоритмическая помехозащита беспилотных летательных аппаратов / В. А. Бухалев, А. А. Скрынников, В. А. Болдинов. Москва : Физматлит, 2018. 188 с.
8. Бенкафо, А. С. Особенности применения фильтров Калмана-Бьюси в комплексах ориентации и навигации / А. С. Бенкафо, А. А. Лобатый // Доклады БГУИР. 2013. № 5. С. 67–71. URL: <https://doklady.bsuir.by/jour/article/view/208/208> (дата обращения: 27.04.2026).
9. Бенкафо, А. С. Оценка навигационных параметров подвижного объекта в условиях многорежимности / А. С. Бенкафо, А. А. Лобатый // Доклады БГУИР. 2014. № 4. С. 52–58. URL: <https://doklady.bsuir.by/jour/article/view/325/325> (дата обращения: 27.04.2026).

REFERENCES

1. Novichkov N.N., editor. *Bespilotnye letatelnye apparaty: spravochnik [Unmanned Aerial Vehicles: Handbook]*. Moscow: ARMS-TASS; 2009. 436 p. (in Russian).
2. Ananyev A.V., Bulgakov M.A., Volobuev M.F., Vyshlov O.S., Dolgov A.A., Kravtsov E.V., et al. *Ekspluatatsiya i primeneniye bespilotnykh letatelnykh apparatov (FPV-dronov): uchebnoe posobie [Operation and Application of*

Unmanned Aerial Vehicles (FPV Drones): Textbook. Voronezh: VUNTS BBS "VVA"; 2023. 235 p. (in Russian).

3. Semak Yu.I. Apparato-programmnyj kompleks operativnogo kontrolya tekhnicheskogo sostoyaniya BLA v polete [Hardware and software complex for operational control of the technical condition of the UAV in flight]. *Aktualnye voprosy nauki i tekhniki v sfere razvitiya aviacii: materialy XV Mezhdunarodnoj nauchno-prakticheskoy konferencii [Topical Issues of Science and Technology in the Field of Aviation Development: Materials of the XV International Scientific and Practical Conference]*. Minsk. 2025. pp. 81 (in Russian).

4. Family of unmanned aircraft systems "Busel", "Busel M" and "Busel M50" for terrain monitoring. *The Republican Center for Technology Transfer* (in Russian). Available at: <https://www.ictt.by/rus/exh/plan/view.php?proid=cd-d3ad7eb0cc77d4f3849f6873ce3c&lng=eng> (accessed 27 April 2026).

5. Kazakov I.E., Artemyev V.M., Bukhalyov V.A. *Analiz sistem sluchajnoj struktury [Analysis of Random Structure Systems]*. Moscow: Nauka; 1993. 270 p. (in Russian).

6. Bukhalyov V.A. *Raspoznavanie, ocenivanie, i upravlenie v sistemah so sluchajnoj skachkoobraznoj strukturoj [Recognition, Estimation, and Control in Systems with Random Discontinuous Structure]*. Moscow: Nauka; 1996. 286 p. (in Russian).

7. Bukhalyov V.A., Skrynnikov A.A., Boldinov V.A. *Algoritmicheskaya pomekhozashchita bespilotnykh letatelnykh apparatov [Algorithmic Interference Protection of Unmanned Aerial Vehicles]*. Moscow: Fizmatlit; 2018. 188 p. (in Russian).

8. Benkafo A.S., Lobaty A.A. Features of application of filters Kalman-Bjusi in orientation and navigation complexes. *Doklady BGUIR [Reports of the BSUIR]*. 2013;(5):67–71 (in Russian). Available at: <https://doklady.bsuir.by/jour/article/view/208/208> (accessed 27 April 2026).

9. Benkafo A.S., Lobaty A.A. Evaluation of moving objects' navigation parameters under multimode. *Doklady BGUIR [Reports of the BSUIR]*. 2014;(4):52–58 (in Russian). Available at: <https://doklady.bsuir.by/jour/article/view/325/325> (accessed 27 April 2026).

A. A. LOBATY¹⁾, Y. I. SEMAK²⁾, L. N. GOTINA¹⁾

DECISION SUPPORT SYSTEM FOR AUTOMATED CONTROL

¹⁾ Belarusian National Technical University
Minsk, Republic of Belarus

²⁾ Scientific and Production Center for Multifunctional Unmanned Systems of the National Academy of Sciences of Belarus
Minsk, Republic of Belarus

Abstract. This article examines the general principles of constructing a decision support system for controlling an unmanned aerial vehicle (UAV) from a ground control station based on measurements and assessment of the technical condition of the UAV's onboard systems. An analysis of current methods for solving such problems is provided, and the use of algorithmic solutions based on stochastic mathematical models of the processes of change in variables characterizing the UAV's technical condition is substantiated. General differential equations describing the evolution of the system under consideration are presented, derived from the theory of systems with random structure changes. A block diagram characterizing the general principles of solving the problem of probabilistic assessment of the system's technical condition is presented, based on which a discrete algorithm for solving the problem of optimal filtering and identification of the operating mode with monitoring process control is derived. An example of solving the problem for simple mathematical models of the process of change in a technical parameter and its measuring device is given, clearly demonstrating the operability of the proposed algorithm.

Keywords: unmanned aerial vehicle, technical condition, probability, structure, filtering, identification

**Лобатый Александр Александрович**

Белорусский национальный технический университет (БНТУ), пр. Независимости, 65, 220013, г. Минск, Республика Беларусь.

Доктор технических наук, профессор. Профессор кафедры «Робототехнические системы» БНТУ. Проводит исследования в области анализа и синтеза систем управления, в том числе – беспилотными летательными аппаратами. Автор и соавтор научных статей, книг и учебных пособий.


Alexander A. Lobaty

Belarusian National Technical University, 65, Nezavisimosty Ave., 220013, Minsk, Republic of Belarus.

Doctor of Science (Engineering), Professor. Professor of the Department of Robotic systems of the Belarusian National Technical University. Conducts research in the field of analysis and synthesis of control systems, including those of unmanned aerial vehicles. Author and co-author of scientific articles, books, and textbooks.

Тел: +375 29 346-82-56

E-mail: lobaty@bntu.by

**Семак Юрий Иванович**

Научно-производственный центр многофункциональных беспилотных комплексов Национальной академии наук Беларуси, ул. Купревича, 10, к.7, 220084, г. Минск, Республика Беларусь.

Кандидат технических наук, доцент. Ведущий научный сотрудник РУП «Научно-производственный центр многофункциональных беспилотных комплексов» НАН Беларуси. Проводит исследования в области теории сложных систем (синергетике) и надежности в технике, в том числе беспилотных систем.

Y. I. Semak

Scientific and Production Center for Multifunctional Unmanned Systems of the National Academy of Sciences of Belarus, 10/7, Kuprevich St., 220084, Minsk, Republic of Belarus.

PhD in Engineering, Associate Professor. Leading Researcher at the Scientific and Production Center for Multifunctional Unmanned Systems of the National Academy of Sciences of Belarus. He conducts research in the field of complex systems theory (synergetics) and reliability in engineering, including unmanned systems.

E-mail: semak.yury@mail.ru

**Готина Любовь Николаевна**

Белорусский национальный технический университет (БНТУ), г. Минск, Республика Беларусь.

Соискатель кафедры «Электропривод и автоматизация промышленных установок и технологических комплексов» БНТУ. Проводит исследования в области анализа и синтеза стохастических систем управления применительно к беспилотным летательным аппаратам.

L. N. Gotina

Belarusian National Technical University, Minsk, Republic of Belarus.

Applicant at the Department of Electric drive and automation of industrial installations and technological complexes, Belarusian National Technical University. Conducts research in the areas of analysis and synthesis of stochastic control systems applied to unmanned aerial vehicles.

E-mail: mathematics@bntu.by

ОБРАБОТКА ИНФОРМАЦИИ И ПРИНЯТИЕ РЕШЕНИЙ

**DATA PROCESSING
AND DECISION-MAKING**

А. А. ЕФРЕМОВ, ГО ЮЙ

ПРИНЯТИЕ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ НА РЫНКЕ КРИПТОВАЛЮТ С ИСПОЛЬЗОВАНИЕМ МОДЕЛИ МАРКОВИЦА И ПРЕДОБУЧЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

Аннотация. В статье рассмотрены современные подходы к формированию оптимального инвестиционного портфеля на рынке криптовалют, включая классические методы технического анализа. Изучены тенденции развития глобального рынка цифровых финансовых активов. Рассмотрены различные трактовки понятия инвестиционной стратегии. Особый акцент сделан на модели Марковица. Рассмотрены ее базовая версия и модификация для криптофьючерсов и криптоопционов. Выполнена компьютерная реализация модели, проведены численные эксперименты с последующей содержательной интерпретацией полученных результатов. Разработан алгоритм решения задачи нелинейной оптимизации с использованием предобученных нейронных сетей и фреймворка Pytorch. Кроме того, рассмотрены альтернативные подходы к оптимизации портфеля криптовалют.

Ключевые слова: принятие решений, нелинейная оптимизация, инвестиции, цифровые финансовые активы, криптовалюты, портфельная теория, модель Марковица, модель Шарпа, предобученные нейронные сети

Введение

В эпоху Web 3.0 цифровые финансовые активы (ЦФА) – криптовалюты, токенизированные активы и другие формы децентрализованных инструментов – стали ключевым драйвером трансформации глобальной экономики. По данным аналитических отчетов Chainalysis за 2025 год [2], объем торгов ЦФА превысил 10 трлн долларов США, что на 45 % больше, чем в предыдущем периоде, однако волатильность этих рынков остается экстремальной: среднесуточные колебания цен достигают 5–15 %.

Широкое распространение криптовалют привело к их повсеместному использованию. По сравнению с акциями, облигациями, паевыми инвестиционными фондами и драгоценными металлами криптовалюты гораздо более гибки в использовании. Монеты BTC и ETH – это больше чем просто инвестиционные активы, они являются формой виртуальных денег. Все больше магазинов, ресторанов, банков уже принимают платежи в криптовалюте, и ожидается только большее признание цифровых денег в качестве платежного инструмента. Кроме этого, стоит отметить, что ряд государств на законодательном уровне приняло криптовалюты как законные средства платежа наравне с национальной фиатной валютой. На наш взгляд, это служит доказательством надежности и дальнейшего развития криптовалют и повсеместное их применение. Это обеспечивает большую гибкость и свободу для инвестора, включая возможность превращать свои активы в товары и услуги одним щелчком мыши.

В Республике Беларусь в 2017 году был принят новаторский Декрет № 8, который подробно описывал систему налогообложения по криптовалютным операциям и механизм их регулирования со стороны государства [1]. Криптовалюту в Беларуси продавать и покупать можно совершенно законно. Важно особо подчеркнуть тот факт, что Беларусь стала первым государством в мире, узаконившим криптовалюты, и первой страной, которая официально зарегистрировала понятие смарт-контракта – компьютерного алгоритма, предназначенного для формирования, управления и предоставления информации о владении чем-либо.

Цель настоящей статьи – разработать и апробировать модель формирования портфеля криптовалют на основе математического аппарата нелинейного программирования и предобученных нейронных сетей для принятия экономически обоснованных инвестиционных решений на рынке ЦФА.

Обзор подходов к принятию инвестиционных решений на рынке криптовалют

Инвестиционная стратегия – план, по которому инвестор покупает и продает различные ценные бумаги либо иные виды активов, в том числе ЦФА [3]. Он включает в себя цель инвестиций, их временной промежуток, выбор инструментов и правила их покупки или продажи. Можно дать и другие определения инвестиционной стратегии, они представлены на рисунке 1.



Рисунок 1. Определения инвестиционной стратегии

Можно сказать, что инвестиционная стратегия – это подробный план действий, который помогает:

- не совершать импульсивных действий;
- выбирать какие ЦФА купить, какие – продать, а также когда именно;
- спрогнозировать примерную доходность на основе истории котировок;
- осознанно принимать собственные решения, а не копировать сделки других инвесторов.

На настоящий момент можно констатировать, что традиционные методы принятия инвестиционных решений, основанные на фундаментальном и техническом анализе (в частности, японские свечи [4], волны Эллиота [5, 6], уровни Фибоначчи [7], полосы Боллинджера [8], осцилляторы RSI и Stochastic [9] и др.), часто оказываются недостаточно эффективными в условиях асимметричной информации, рыночного шума и действия поведенческих факторов, что приводит к систематическим ошибкам в прогнозировании и разработке трейдинговой стратегии.

Прикладной искусственный интеллект (в частности, технологии глубокого обучения) предлагает мощный инструмент для преодоления этих ограничений. Сегодня нейронные сети, эволюционировавшие от простых (однослойных) перцептронов к глубоким архитектурам (LSTM, Transformer, GAN), демонстрируют превосходство в обработке нелинейных зависимостей, больших объемов высокочастотных данных и выявлении скрытых паттернов. В контексте ЦФА предобученные нейронные сети успешно применяются для прогнозирования цен (например, модели на базе Gated Recurrent Units), оценки рисков и оптими-

зации портфелей, как показано в работах [10] и [11], где точность предсказаний превышала 70 % на данных Bitcoin и Ethereum. В работе [12] рассматривается комбинация средств технического анализа и рекуррентных нейронных сетей для построения успешной торговой стратегии.

Несмотря на прогресс, существующие исследования фокусируются преимущественно на краткосрочном трейдинге, игнорируя долгосрочные инвестиционные стратегии и интеграцию мультимодальных данных (тексты из соцсетей, on-chain метрики, макроэкономические индикаторы).

Для разработки инвестиционной стратегии в аспекте формирования портфеля криптовалют могут применяться различные подходы. Наиболее классическим из них считается портфельная теория Марковица. Разработанная Гарри Марковицем методика формирования инвестиционного портфеля, направленная на оптимальный выбор активов, исходя из требуемого соотношения доходность/риск [12]. Как правило, решается две задачи: максимизация доходности при заданном уровне риска и минимизация риска при минимально допустимом значении доходности.

Доходность портфеля ЦФА измеряется как средневзвешенная сумма доходностей, входящих в него криптовалют, по формуле:

$$r_p = \sum_{i=1}^n w_i \cdot r_i, \quad (1)$$

где r_i – доходность i -го ЦФА, w_i – доля ЦФА в портфеле.

Риск отдельного инструмента оценивается как среднее квадратичное отклонение его доходности. Для расчета общего риска портфеля необходимо отразить совокупное изменение рисков отдельного инструмента и их взаимное влияние, что нашло отражение в следующей формуле:

$$\delta_p = \sqrt{w_i \cdot w_j \cdot V_{ij}} = \sqrt{\sum_{i=1}^n w_i^2 \cdot \sigma_i^2 + 2 \cdot \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i \cdot w_j \cdot k_{ij} \cdot \sigma_i \cdot \sigma_j}, \quad (2)$$

где σ_i – стандартное отклонение доходностей i -го ЦФА, k_{ij} – коэффициент корреляции между i -м и j -м ЦФА, V_{ij} – ковариация доходностей i -го и j -го ЦФА, n – количество потенциально рассматриваемых для включения в инвестиционный портфель ЦФА.

Таким образом, в рамках грамотным образом скомбинированного портфеля риски снижаются за счет обратной корреляции входящих в его состав ЦФА (эффект диверсификации).

Для составления портфеля решаются задачи нелинейной оптимизации в двух базовых постановках. Модель для минимизации риска портфеля криптовалют при заданном уровне его доходности $\hat{r}_p$ имеет вид:

$$\left\{ \begin{array}{l} \sum_{i=1}^n w_i^2 \cdot \sigma_i^2 + 2 \cdot \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i \cdot w_j \cdot k_{ij} \cdot \sigma_i \cdot \sigma_j \rightarrow \min, \\ \sum_{i=1}^n w_i \cdot r_i \geq \widehat{r}_p, \\ \sum_{i=1}^n w_i = 1, \\ w_i \geq 0. \end{array} \right. , \quad (3)$$

Модель для максимизации доходности портфеля криптовалют при заданном уровне его риска $\widehat{\sigma}_p$ имеет вид:

$$\left\{ \begin{array}{l} \sum_{i=1}^n w_i \cdot r_i \rightarrow \max, \\ \sum_{i=1}^n w_i^2 \cdot \sigma_i^2 + 2 \cdot \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i \cdot w_j \cdot k_{ij} \cdot \sigma_i \cdot \sigma_j \leq \widehat{\sigma}_p, \\ \sum_{i=1}^n w_i = 1, \\ w_i \geq 0. \end{array} \right. \quad (4)$$

Следует отметить, что при интерпретации результатов оптимизации нужно учитывать делимость монет (что избавляет от необходимости добавления условия целочисленности). Так, например, 1 биткоин делится на 100 млн сатоши, и потому его значение может указываться с 8 знаками после запятой.

Апробация модели

Основной проблемой компьютерной реализации моделей (3) и (4) является их нелинейный характер, а также возрастающая сложность при росте количества рассматриваемых инструментов. Так,

встроенный в Excel «Поиск решения» имеет существенные ограничения на размерность задач, решаемых методом ОПГ (обобщенного приведенного градиента). Альтернативой может стать эволюционный поиск решения, т.к. на управляемые переменные легко накладываются ограничения в виде двойного неравенства (доли бумаг в портфеле варьируются от 0 до 1). Однако и в этом случае возможны сбои в работе оптимизационных алгоритмов. К тому же указанные ограничения не всегда выполняются, о чем мы подробнее расскажем ниже.

В связи с этими обстоятельствами возникает необходимость в создании подхода, позволяющего быстро и эффективно находить оптимальное решение. В этом случае можно обратиться к аппарату предобученных нейронных сетей, в которых поставленные задачи могут быть реализованы с использованием специализированного фреймворка Руомо, который предназначен для нахождения близкого к оптимальному решения на основе методов глубокого обучения и средств языка Python. Руомо использует open-source решения, включая натренированные на аналогичных задачах математического программирования алгоритмы и специализированные программы-солверы.

Следующим этапом является подготовка исходных данных для проведения численного эксперимента. Прежде всего необходимо выбрать криптовалюты для потенциального инвестирования. На сегодняшний день около 60 % капитализации глобального рынка ЦФА приходится на Биткоин (BTC), хотя в последние годы и другие проекты демонстрируют заметный рост. Любопытным является тот факт, что в «медвежьих» фазах этот показатель растет, подчеркивая роль BTC как «безопасной гавани» для криптоинвесторов. Среди остальных ЦФА (так называемых альткоинов) доминирующие позиции занимает Эфириум (ETH) – около 16 % от общего рынка. Ключевые характеристики сегментов рынка ЦФА и их основные характеристики представлены в таблице 1.

Таблица 1. Основные сегменты рынка ЦФА

Сегмент рынка	Доля, %	Основные примеры	Краткая характеристика
BTC	58–60	Bitcoin	«Цифровое золото», относительно низкая волатильность ($\sigma \sim 40\%$), ETF-драйвер (определяет динамику трейдинга других ЦФА)
ETH & Layer1	15–18	Ethereum, Solana, BNB	Основаны на смарт-контрактах и концепции DeFi
Альткоины	20–25	Top-50 (DOGE, XRP, ADA и др.)	Высокий риск/доходность (спекулятивные инструменты)
Стейблкоины	7–10	USDT, USDC, DAI	Ликвидность, объем торгов > 50 %
Токенизированные	2–5	RWA (Real World Assets) – активы, имеющие реальное обеспечение (например, недвижимость, облигации)	Реальные активы, регулирующиеся со стороны государства

Для демонстрации работы модели Марковица рассмотрим механизм формирования оптимального портфеля из семи потенциальных криптовалют. По ито-

гам решения оптимизационных задач (3) и (4) при заданных нами исходных условиях мы получим долю каждого из инструментов в оптимальном инвестиционном

портфеле. Результаты решения оптимизационных задач (3) и (4) представлены в таблицах 2 и 3 соответственно.

Таблица 2. Результаты решения задачи максимизации доходности портфеля с включением высокодоходного криптоактива

Криптоактив	Доля в портфеле
BITCOIN	0.00 %
ETHEREUM	0.00 %
SOLANA	0.00 %
HYPERLIQUID	3.02 %
THE-OPEN-NETWORK	0.00 %
MANTLE	0.00 %
MONERO	0.00 %
ZCASH	96.98 %
Коэффициент Шарпа (годовой)	1,815

Любопытно, что в данном случае модель рекомендует приобретать в основном «второстепенный» актив, хотя для потенциального включения в портфель рассматривались и такие «мастодонты» крипторынка, как Биткоин и Эфириум. Этот парадокс можно объяснить тем, что Zcash демонстрировал в краткосрочной ретроспективе небольшой прирост, что на фоне общего падения рынка интерпретировалось моделью Марковица как высокий уровень доходности. Таким образом, очевидным является тот факт, что предлагаемый подход может применяться лишь для принятия инвестиционных решений на самую ближайшую перспективу. Для более долгосрочных вложений следует проводить комплексный анализ рыночной конъюнктуры, включающий идентификацию макротрендов.

Если одна из монет обладает значительно большим ростом относительно других исследуемых монет, то модель Марковица создаст портфель из одной монеты. В связи с этим рассмотрим модель с добавлением дополнительного ограничения, лимитирующего максимальную долю одного актива в портфеле в целях соблюдения принципа диверсификации (см. таблицу 3).

Таблица 3. Результаты решения задачи максимизации доходности портфеля с дополнительным ограничением

Криптоактив	Доля в портфеле
BITCOIN	35.00 %
ETHEREUM	0.00 %
SOLANA	0.00 %
HYPERLIQUID	2.80 %
THE-OPEN-NETWORK	29.34 %
MANTLE	4.44 %
MONERO	28.42 %
Коэффициент Шарпа (годовой)	1,133

Таким образом, при ограничении максимальной доли одного актива до 35 % модель распределит доли минимизируя риски вкладывая в наименее волатиль-

ные монеты. Данный портфель обеспечивает 1,133 единицу прибыли на 1 единицу риска.

При ограничении максимальной доли до 40 % модель распределит вложения, максимизируя прибыль и вкладывая в наиболее доходные монеты. Данный портфель обеспечивает 1,143 единицу прибыли на 1 единицу риска. Также стоит учитывать, что в данном портфеле 40 % занимает безрисковый USDT (см. таблицу 4). При падающем рынке эта стратегия приносит больше прибыли (сравните значения коэффициента Шарпа в таблицах 3 и 4).

Таблица 4. Результаты оптимизации с включением безрискового актива

Криптоактив	Доля в портфеле
BITCOIN	40.00 %
ETHEREUM	0.00 %
SOLANA	0.00 %
HYPERLIQUID	0.00 %
THE-OPEN-NETWORK	9.45 %
MANTLE	0.00 %
MONERO	10.55 %
TETHER (USDT)	40.00 %
Коэффициент Шарпа (годовой)	1,143

Модификации базовой модели

Следует особо отметить, что значительный интерес представляют также модификации представленных выше базовых версий модели Марковица, в которых последние ограничения (на неотрицательность долей) отсутствуют в силу наличия опции так называемых «коротких продаж». Действительно, на рынке криптовалют широкое распространение получили производные финансовые инструменты. Так, сегодня инвесторами активно торгуются криптофьючерсы и криптоопционы. Первые популярны на биржах Bybit, Binance, CME Group и включают срочные контракты и «бессрочные свопы» (без даты экспирации). Вторые торгуются на Deribit, Binance, OKX и позволяют хеджировать риски (страховаться) или спекулировать, используя контракты типа «колл» (на рост) и «пут» (на падение).

Считается, что криптофьючерсы чаще используются для агрессивной торговли с «плечом», тогда как криптоопционы используют для более гибких стратегий. Кредитное «плечо» – это стратегия, позволяющая торговать фьючерсными контрактами, не оплачивая полную стоимость контракта заранее. Трейдеры могут получить заем капитала, необходимого для финансирования контракта, предоставив относительно меньшую долю участия.

Другие модели оптимизации портфеля криптовалют

Следует отметить, что помимо модели Марковица в современной научной литературе выделяются и другие

методические подходы к оптимизации портфеля активов. Так, на наш взгляд, заслуживает внимания модель Шарпа [13]. Ее суть заключается в том, что специалисты нередко отдельно рассматривают задачу формирования оптимального портфеля с учетом опции приобретения обращающихся на рынке безрисковых активов. При данной модификации целевая функция представляет собой максимизируемый коэффициент Шарпа – показатель эффективности инвестиционного портфеля (актива), который вычисляется как отношение средней премии за риск к среднему отклонению портфеля.

Необходимо выбрать безрисковую инвестицию для подсчета коэффициента Шарпа. Например, вклады в очень надежном банке или государственные облигации. Эти инвестиции практически всегда обеспечены государством или организацией, шанс на дефолт которой минимален. В случае криптовалютного рынка подобными активами можно считать так называемые стейблкоины.

Полученный коэффициент Шарпа необходимо интерпретировать следующим образом:

- если коэффициент становится отрицательным, то доходность портфеля ниже безрисковой;
- если коэффициент больше нуля, но меньше единицы, то риск не окупается. Такие портфели можно использовать, если нет альтернатив;
- если коэффициент превышает единицу, это означает, что риск окупается, и портфель можно использовать;
- если коэффициент больше 3, то это означает, что вероятность получить убыток в сделке может быть оценена как близкая к нулю (составляет меньше 1 %).

Коэффициент Шарпа представляет собой достаточно простой и наглядный инструмент для оценки различных активов по соотношению доходность/риск. Хотя коэффициент Шарпа применим для оценки отдельных активов, в общепринятой инвестиционной практике он используется для оценки портфелей.

Помимо модели Шарпа исследователи предлагают адаптировать к задаче оптимизации портфеля криптовалют такие подходы, как использование коэффициента Трейнора и коэффициента Дженсена [14].

Таким образом, существует множество различных способов для формирования инвестиционной стратегии на криптовалютном рынке, однако необходимо понимать, что все стратегии, которые формируются в результате различных математических расчетов, носят рекомендательный характер, они лишь могут подсказать какой выбор необходимо сделать в момент принятия решения об инвестировании, но не могут точно предугадать рыночную конъюнктуру.

Заключение

Полномасштабное внедрение ЦФА в повседневную жизнь пока не достигнуто, но такая тенденция имеет место. Рынок ЦФА является достаточно молодым и нестабильным. Необходимо обратить внимание на стоимость криптовалют, которая изменяется постоянно, и часто разница составляет сотни процентов за месяцы или даже недели. Например, в 2016 году цена за одну монету BTC была равна 600 долларам. На февраль 2026 года курс BTC превышает 67 000 долларов. Тем самым можно сказать, что инвесторы, которые вложили свои средства тогда, уже увеличили свой капитал в 112 раз (без учета инфляции). Однако стоит учитывать, что есть и те, кто купил монету BTC на пиковых ценах (например, в октябре 2025 года курс составлял более 126 000 долларов), а позже ее цена снизилась.

Исходя из этого можно сказать, что инвестиции в ЦФА являются довольно рискованными. Однако набирающие популярность криптовалюты становятся подходящим инструментом для вложений физических лиц по всему миру. Инвестирование в криптовалюты немыслимо без создания портфеля, что предполагает использование специфических методов и средств, направленных на диверсификацию и достижения высокой доходности при минимально возможном риске.

Высокая волатильность криптовалют также играет роль в выборе объекта для инвестирования. Это одновременно является и плюсом, и минусом цифровых финансовых активов. Цены на рынке криптовалют нестабильны и очень часто на них влияют факторы, которые невозможно предугадать или предположить. Крайне трудно формализовать механизм воздействия определенных событий на поведение курса криптовалюты. Например, можно вспомнить случаи, когда Илон Маск, размещая публикации в социальной сети X о каких-то своих действиях либо мнениях, резко повышал или понижал курс и стоимость криптовалют. Аналогично, события, произошедшие в Казахстане в начале 2022 года, существенно снизили курс монеты BTC, потому что в стране на тот момент была сосредоточена значительная часть от мировой добычи биткоина.

Таким образом, грамотное сочетание классических подходов к принятию решений на рынке криптовалют с новейшими достижениями в области развития технологий искусственного интеллекта способно обеспечить инвесторам устойчивое прибыльное состояние и открывает новые возможности для широкого внедрения алгоритмов автоматизированной торговли.

ЛИТЕРАТУРА

1. О развитии цифровой экономики : Декрет Президента Республики Беларусь от 21 декабря 2017 г. № 8 // Национальный правовой Интернет-портал Республики Беларусь. URL: <https://pravo.by/document/?guid=12551&p0=Pd1700008> (дата обращения: 21.02.2026).
2. The 2025 Geography of Crypto Report // Chainalysis. URL: <https://www.chainalysis.com/reports/2025-geo-crypto-report/> (date of access: 22.02.2026).

3. Ихсанов, И. Р. Анализ инвестиционных стратегий в криптовалюту / И. Р. Ихсанов // Тенденции развития науки и образования. 2022. № 87(3). С. 157–161. DOI: 10.18411/trnio-07-2022-122.
4. Технический анализ как инструмент формирования инвестиционных решений на рынке акций / О. В. Ваганова, Н. С. Мельникова, А. С. Буряк, М. Н. Пузанков // *Modern Economy Success*. 2025. № 6. С. 347–354. URL: <https://journals.rcsi.science/2500-3747/article/view/369340> (дата обращения: 22.02.2026).
5. Малышенко, К. А. Теория Эллиотта и ее значение в развитии фондового рынка / К. А. Малышенко, В. А. Малышенко, Э. Ю. Терещенко // *Экономика, социология и право*. 2017. № 6. С. 11–18.
6. Волобуева, Е. А. О возможностях применения системы Bloomberg для исследования цен акций на основе волновой теории Эллиота / Е. А. Волобуева // *Современная математика и концепции инновационного математического образования : материалы Всероссийской конференции, Москва, 19 мая 2015 г. / Финуниверситет ; В. Л. Куликов, Е. Ф. Олехова, Е. Н. Орел [и др.] ; редкол.: В. Б. Гисин [и др.]. Москва, 2015. С. 173–178. URL: http://elibrary.ru/fbook/gisin_sovremennay_matematika_sbornik.pdf (дата обращения: 21.02.2026).*
7. Чемяков, Р. А. Уровни Фибоначчи в трейдинге / Р. А. Чемяков // *Научному прогрессу – творчество молодых : материалы XVIII международной молодежной научной конференции по естественнонаучным и техническим дисциплинам, Йошкар-Ола, 21–22 апреля 2023 г. : в 2 ч. / Поволжский государственный технологический университет ; редкол.: Д. В. Иванов [и др.]. Йошкар-Ола, 2023. Ч. 2. С. 391–394. URL: <https://science.volgatech.net/nm/Conferences/Young%20creations/sbornic2.pdf> (дата обращения: 21.02.2026).*
8. Диголь, И. Д. Оценка эффективности фильтрационных методов технического анализа: скользящие средние и полосы Боллинджера / И. Д. Диголь // *Russian Economic Bulletin*. 2023. Т. 6, № 3. С. 266–273 URL: <https://journals.rcsi.science/2658-5286/article/view/403474/671212> (дата обращения: 21.02.2026).
9. Карпова, А. Н. Технический анализ как метод прогнозирования криптовалютного рынка / А. Н. Карпова, М. В. Дубатовская // *Основные тенденции экономического развития Республики Беларусь : сборник докладов II Научно-практического Круглого стола преподавателей, аспирантов и студентов, Минск, 15 апреля 2020 г. / БГУ; редкол.: А. М. Сидорова (отв. ред.) [и др.]. Минск : БГУ, 2020. С. 226–233. URL: <https://elibrary.bsu.by/handle/123456789/250997>.*
10. Review of deep learning models for crypto price prediction: implementation and evaluation / J. Wu, X. Zhang, F. Huang [et al.]. 2024. DOI: 10.48550/arXiv.2405.11431.
11. Attention-augmented hybrid CNN-LSTM model for social media sentiment analysis in cryptocurrency investment decision-making / D. Tiwari, B. S. Bhati, B. Nagpal [et al.]. *Scientific Reports*. 2025. Vol. 15. DOI: 10.1038/s41598-025-18245-x.
12. Манкелевич, П. В. Комбинированное применение рекуррентной нейронной сети и технического анализа для прогнозирования изменения цен на рынке криптовалют / П. В. Манкелевич // *Форум молодых ученых*. 2019. № 5(33). С. 877–880. URL: <https://cyberleninka.ru/article/n/kombinirovanное-primenenie-rekurrentnoy-neyronnoy-seti-i-tehnicheskogo-analiza-dlya-prognozirovaniya-izmeneniya-tsen-na-rynke> (дата обращения: 21.02.2026).
13. Федоров, Г. В. Применение теории Марковица к криптовалютному портфелю / Г. В. Федоров // *Белгородский экономический вестник*. 2023. № 2(110). С. 91–95.
14. Ермаков, Н. С. Оптимизация портфеля в эпоху цифровой финансовизации с использованием криптовалют / Н. С. Ермаков, Е. А. Галкина // *Modern Economy Success*. 2021. № 2. С. 164–169.
15. Оптимизация портфеля в эпоху цифровой финансовизации с использованием криптовалют / А. А. Халяпин, Т. В. Стрельцова, А. А. Милованов, С. А. Ким // *Естественно-гуманитарные исследования*. 2025. № 1(57). С. 533–538. URL: <https://cyberleninka.ru/article/n/optimizatsiya-portfelya-v-epohu-tsifrovoy-finansializatsii-s-ispolzovaniem-kriptovalyut> (дата обращения: 21.02.2026).

REFERENCES

1. O razvitiy tsifrovoy ekonomiki : Dekret Prezidenta Respubliki Belarus ot 21 dekabrya 2017 g. № 8 [On the development of the digital economy : Decree of the President of the Republic of Belarus of December 21, 2017 No 8]. *National Legal Internet Portal of the Republic of Belarus* (in Russian). Available at: <https://pravo.by/document/?guid=12551&p0=Pd1700008> (accessed 21 February 2026).
2. The 2025 geography of crypto report. *Chainalysis*. Available at: <https://www.chainalysis.com/reports/2025-geo-crypto-report/> (accessed 22 February 2026).
3. Ikhsanov I.R. Analiz investitsionnykh strategiy v kriptovalyutu [Analysis of investment strategies in cryptocurrency]. *Tendentsii Razvitiya Nauki i Obrazovaniya [Trends in the Development of Science and Education]*. 2022;87(3):157–161 (in Russian). doi: 10.18411/trnio-07-2022-122.
4. Vaganova O.V., Melnikova N.S., Buryak A.S., Puzankov M.N. Technical analysis as a tool for forming investment decisions in the stock market. *Modern Economy Success*. 2025;6:347–354 (in Russian). Available at: <https://journals.rcsi.science/2500-3747/article/view/369340> (accessed 22 February 2026).
5. Malyschenko K.A., Malyschenko V.A., Tereshchenko E.Yu. Teoriya Elliotta i ee znacheniye v razvitiy fondovogo

rynka [Elliott theory and its importance in the development of the stock market]. *Ekonomika, Sotsiologiya i Pravo* [Economics, Sociology and Law]. 2017;6:11–18 (in Russian).

6. Volobueva E. About capabilities of application of Bloomberg system for research of the stock prices based on Elliott wave theory. *Sovremennaya Matematika i Kontseptsii Innovatsionnogo Matematicheskogo Obrazovaniya: Materialy Vserossiyskoy Konferentsii* [Modern Mathematics and Concepts of Innovative Mathematical Education: Proceedings of the All-Russian Conference], Moscow, May 19, 2015. Moscow; 2015. pp. 173–178 (in Russian). Available at: http://elibrary.ru/fbook/gisin_sovremennaya_matematika_sbornik.pdf (accessed 21 February 2026).

7. Chemekov R.A. Urovni Fibonachchi v treidinge [Fibonacci retracements in trading]. *Nauchnomu Progressu – Tvorchestvo Molodykh: Materialy XVIII Mezhdunarodnoi Molodezhnoi Nauchnoi Konferentsii po Estestvennonauchnym i Tekhnicheskim Disttsiplinam* [Scientific Progress – Creativity of the Young: Proceedings of the XVIII International Youth Scientific Conference on Natural Sciences and Engineering Disciplines], Yoshkar-Ola, April 21–22, 2023. In 2 parts. Yoshkar-Ola; 2023. Part 2. pp. 391–394 (in Russian). Available at: <https://science.volgatech.net/nm/Conferences/Young%20creations/sbornic2.pdf> (accessed 21 February 2026).

8. Digol I.D. Effectiveness of technical analysis filtering methods: moving averages and Bollinger bands. *Russian Economic Bulletin*. 2023;6(3):266–273 (in Russian). Available at: <https://journals.rcsi.science/2658-5286/article/view/403474/671212> (accessed 21 February 2026).

9. Karpova A.N., Dubatovskaya M.V. Technical analysis as a method of forecasting the cryptocurrency market. *Osnovnye Tendentsii Ehkonomicheskogo Razvitiya Respubliki Belarus: Sbornik Dokladov II Nauchno-prakticheskogo Kruglogo Stola Prepodavatelei, Aspirantov i Studentov* [Main Trends in the Economic Development of the Republic of Belarus: Collection of Reports of the II Scientific and Practical Round Table of Teachers, Graduate Students and Students], Minsk, April 15, 2020. Minsk; 2020. pp. 226–233 (in Russian). Available at: <https://elibrary.bsu.by/handle/123456789/250997>.

10. Wu J., Zhang X., Huang F., Zhou H., Chandra R. Review of deep learning models for crypto price prediction: implementation and evaluation. *arXiv* [Preprint]. 2024. <https://doi.org/10.48550/arXiv.2405.11431>.

11. Tiwari D., Bhati B.S., Nagpal B., Alturki N., Bayisenge L. Attention-augmented hybrid CNN-LSTM model for social media sentiment analysis in cryptocurrency investment decision-making. *Scientific Reports*. 2025;15:33201. <https://doi.org/10.1038/s41598-025-18245-x>.

12. Mankialevich P.V. Combined application of the recurrent neural network and technical analysis for predicting the change in the prices of the cryptate market. *Forum Molodykh Uchenykh* [Forum of Young Scientists]. 2019;5(33):877–880 (in Russian). Available at: <https://cyberleninka.ru/article/n/kombinirovannoe-primeneniye-rekurrentnoy-neyronnoy-seti-i-tehnicheskogo-analiza-dlya-prognozirovaniya-izmeneniya-tsen-na-rynke> (accessed 21 February 2026).

13. Fedorov G. V. Primenenie teorii Markovitsa k kriptovalyutnomu portfelyu. [Application of Markowitz's theory to a cryptocurrency portfolio]. *Belgorodskii Ehkonomicheskii Vestnik* [Belgorod Economic Bulletin]. 2023;2(110):91–95 (in Russian).

14. Ermakov N.S., Galkina E.A. Portfolio optimization in the era of digital financialization using cryptocurrencies. *Modern Economy Success*. 2021;2:164–169 (in Russian).

15. Khalyapin A.A., Streltsova T.V., Milovanov A.A., Kim S.A. Portfolio optimization in the era of digital financialization using cryptocurrencies. *Estestvenno-gumanitarnye Issledovaniya* [Natural Sciences and Humanities Studies]. 2025;1(57):533–538 (in Russian). Available at: <https://cyberleninka.ru/article/n/optimizatsiya-portfelya-v-epohu-tsifrovoy-finansializatsii-s-ispolzovaniem-kriptovalyut> (accessed 21 February 2026).

A. A. EFREMOV, GUO YU

MAKING INVESTMENT DECISIONS IN THE CRYPTOCURRENCY MARKET USING THE MARKOWITZ MODEL AND PRE-TRAINED NEURAL NETWORKS

Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus

Abstract. The article examines modern approaches to forming an optimal investment portfolio in the cryptocurrency market, including classical methods of technical analysis. Trends in the development of the global digital financial assets market are studied. Various interpretations of the concept of investment strategy are considered. Particular emphasis is placed on the Markowitz model. Its basic version and modification for crypto-futures and crypto-options are reviewed. A computer implementation of the model was developed, numerical experiments were conducted, followed by a substantive interpretation of the obtained results. An algorithm for solving the nonlinear optimization problem using pre-trained neural networks and the Pyomo framework was developed. Additionally, alternative approaches to cryptocurrency portfolio optimization are considered.

Keywords: decision-making, nonlinear optimization, investments, digital financial assets, cryptocurrencies, portfolio theory, Markowitz model, Sharpe model, pre-trained neural networks

Ефремов Андрей Александрович

Белорусский государственный университет информатики и радиоэлектроники (БГУИР), г. Минск, Республика Беларусь.

Кандидат экономических наук, доцент, заведующий кафедрой экономической информатики, доцент кафедры интеллектуальных информационных технологий. Область научных интересов: нелинейные и негладкие оптимизационные модели большой размерности, теория принятия решений, цифровая трансформация экономики.

A. A. Efremov

Belarusian State University of Informatics and Radioelectronics (BSUIR), Minsk, Republic of Belarus.

PhD in Economics, Associate Professor, Head of the Department of Economic Informatics, Associate Professor at the Department of Intellectual Information Technologies.

Research interests include nonlinear and nonsmooth high-dimensional optimization models, decision-making theory, digital transformation of economics.

E-mail: efremov.kafei@gmail.com

Го Юй

Белорусский государственный университет информатики и радиоэлектроники (БГУИР), г. Минск, Республика Беларусь.

Аспирант кафедры информационных технологий автоматизированных систем. Область научных интересов: методы глубокого обучения, автоматизированная торговля на рынках цифровых активов.

Guo Yu

Belarusian State University of Informatics and Radioelectronics (BSUIR), Minsk, Republic of Belarus.

Postgraduate Student of the Department of Information Technologies in Automated Systems. The area of scientific interests is related to deep learning methods and automated trading in digital assets markets.

E-mail: 305619456@qq.com

Д. В. ЗАЕРКО¹⁾, Н. Л. БОБРОВА¹⁾, Дм. В. ЗАЕРКО²⁾

ОЦЕНКА ТОНОВОЙ ДЕВИАЦИИ ГРАНИЧНЫХ ПИКСЕЛЕЙ СТАТИЧЕСКОГО РАСТРОВОГО ИЗОБРАЖЕНИЯ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМА СБАЛАНСИРОВАННОГО «ДООПРЕДЕЛЕНИЯ»

¹⁾ Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

²⁾ Гродненский государственный университет имени Янки Купалы
г. Гродно, Республика Беларусь.

Аннотация. Использование алгоритмов предварительной обработки растровых изображений предполагает улучшение набора характеристик изображения для использования полученного качественного эффекта преобразований на последующих этапах процесса обработки. Оценка эффекта воздействия на растровое изображение является нетривиальной задачей, от качества ее решения зависит выбор дальнейших шагов обработки и алгоритмического инструментария. Примером может быть алгоритм сбалансированного «доопределения» граничных пикселей изображения, разработанный для улучшения результатов работы алгоритмов выделения контуров объектов и основанный на операции двумерной свертки, где улучшение заключается в сокращении числа резко контрастирующих пикселей на границах растровых изображений относительно смежных. Существующие численные оценки PSNR и SSIM растровых изображений, полученных после применения алгоритма сбалансированного «доопределения», показали свою малую эффективность из-за малого числа пикселей, затрагиваемых преобразованиями. Альтернативным критерием является оценка тоновой девиации пикселей на границах растрового изображения. Объект исследования – пиксельная матрица цветного трехканального статического растрового изображения. Предмет изучения – оценка тоновой девиации граничных пикселей статического растрового изображения, полученных с использованием алгоритма сбалансированного «доопределения». Основная цель – вычисление оценки тоновой девиации граничных пикселей статического растрового изображения после применения алгоритма сбалансированного «доопределения», анализ и ранжирование альтернативных методов «доопределения» граничных пикселей по критерию тоновой девиации. В статье приводится определение понятия и обоснование использования оценки тоновой девиации. Представлен пример вычисления тоновой девиации пикселей после применения алгоритма сбалансированного «доопределения» и метода копирования для 1 тыс. цветных трехканальных растровых изображений из датасета SpaceNet Satellite Images от ImageNet. Проведен краткий анализ полученных результатов оценок, даны рекомендации к выбору лучшего метода «доопределения».

Ключевые слова: растровые изображения, пиксельная матрица, граничные пиксели, доопределенные пиксели, выделение контуров объектов, фильтр Собеля, SSIM, PSNR, оценка тоновой девиации пикселей

Введение

Работа алгоритмов предварительной обработки растровых изображений предполагает промежуточную оценку результатов преобразований над ними и характеристик работы самого алгоритма. Использование оценки экспертного типа носит субъективный характер и не всегда выполнимо в условиях конвейерной обработки большого объема растровых изображений, различных по своему первоначальному качеству и разрешению. Особенно затруднителен выбор методики оценки в случае специфических преобразований, выполняемых над изображениями, и оценкой отдельных интересующих характеристик, изменение которых не приводит к изменению величины этих оценок. В этом случае необходимо выстраивать собственную методику оценки характеристик, часто опираясь на возможности статистического аппарата и оценивая изменение характеристики по среднему выборочному значению (математическому ожиданию), выборочной дисперсии,

среднеквадратическому отклонению изменения базовых свойств изображения. Альтернативным вариантом оценки могут выступать классы общепринятых оценок [1], которые в последнее время получают аргументируемую критику в их справедливости [2, 3]. Наиболее общие оценки качества растровых изображений, такие как SSIM и PSNR, могут не в полной мере демонстрировать отличия оригинального и преобразованного некоторым способом изображения, например, в случае малого числа преобразуемых тонов пикселей. Примером может быть случай «доопределения» пикселей вне границ статического растрового изображения для корректного выделения контуров объектов фильтром Собеля, использующим операцию двумерной свертки и требующим дополнительный набор пикселей вне границ оригинального растрового изображения [4, 5].

«Доопределение» граничных тонов пикселей в алгоритмах сегментации контуров объектов растровых изображений на базе операции двумер-

ной свертки, оценка тоновой девиации пикселей. Задача «доопределения» дополнительного набора пикселей вне границ оригинального растрового изображения широко известна [6]. Она связана с необходимостью «доопределения» пикселей вне границ первоначального изображения для корректной работы алгоритмов, использующих операцию двумерной свертки на его границах, и одновременного заполнения неконтрастирующих значений тонов относительно близлежащих смежных. Необходимость дополнительного набора пикселей вне границ следует из особенностей работы операторов двумерной свертки – последние граничные пиксели не будут обработаны из-за выхода алгоритма за пределы границ исходного изображения. Ранее в исследованиях сообщалось, что практический интерес «доопределения» граничных тонов пикселей на границах статического растрового изображения связан с применением их в операции двумерной свертки, с различными ядрами свертки [4, 5]. Эффект воздействия «доопределенных» пикселей с их контрастирующими значениями будет существенным образом влиять на результат однократного применения операции двумерной свертки из-за особенности принципа ее работы, независимо от выбранного вида ядра. Воздействие будет распространяться в направлении центра изображения с постепенным затуханием эффекта. Особенно эффект ошибочного контрастирующего «доопределения» проявляется в алгоритмах выделения контуров объектов, где оцениваются «резкие» изменения тонов пикселей. Для решения указанной выше задачи был разработан и предложен алгоритм сбалансированного «доопределения» тонов пикселей [4, 5]. В ходе разработки алгоритма и при его практическом применении возникла проблема оценки изменений, возникающих после его использования. Оценка и анализ работы алгоритма сбалансированного «доопределения» граничных пикселей возможен по следующим критериям. *Оценка визуальных эффектов*, вызванных «доопределенными» пикселями на границах изображения, и их влияния на процесс дальнейшей обработки изображения алгоритмами нелинейной фильтрации для выделения контуров объектов. Под визуальным эффектом подразумевается появление отдельных отличающихся по тону пикселей, множества точек, линий или областей, не содержащихся на оригинальном изображении, и их ложное использование при оценке яркостных характеристик на них. Данный критерий практически осложнен тем, что при оценке работы алгоритмов на большой базе растровых изображений требуется наличие эксперта. *Численная оценка* «доопределенных» пикселей представляется их статистическими оценками, изменением выборочного среднего и выборочной дисперсии до и после включения «доопределенных» значений тонов пикселей, PSNR и SSIM оценками. Использование PSNR и SSIM является общепринятой практикой оценки изменений растрового изображения. Однако в связи

с небольшим числом «доопределяемых» пикселей относительно их общего числа значение оценки изменяется несущественно и не дает ясного понимания степени влияния «доопределенных» пикселей на последующее выделение контуров объектов. Альтернативным критерием оценки алгоритмов является анализ тоновой девиации «доопределенных» пикселей растрового изображения. При условии, что тон «доопределенного» пикселя – это дискретная случайная величина, изменяющая свое значение байт в границах $x \in [0, 255]$, тогда оценка выборочного среднего

$$\overline{pel} = \frac{1}{n} \sum_{i=1}^n pel_i \text{ и несмещенной выборочной дисперсии}$$

$$D = \frac{1}{n} \sum_{i=1}^n (pel_i - \overline{pel})^2, \text{ где } pel_1, \dots, pel_n - \text{значения } n \text{ тонов пикселей.}$$

Наличие резкого изменения дисперсионной оценки или среднего значения указывает на **тоновое отличие** «доопределенных» значений, которые будут визуально проявляться при выходе за некоторый диапазон допустимого перепада тонов. На практике величина диапазона варьируется в зависимости от общей тоновой характеристики анализируемых изображений. Чем меньше диапазон колебаний значений и разность между выборочным средним до и после применения алгоритма «доопределения», тем эффективнее выбранный алгоритм. *Таким образом, тоновая девиация растрового изображения – это модуль сумм приращений выборочных дисперсий «доопределенного» и близлежащих смежных к «доопределяемому» тонов пикселей, до и после применения алгоритма «доопределения» граничных пикселей растрового изображения.* Особый интерес представляет не только оценка тоновой девиации растрового изображения, характеризующая «приращение» значений растрового изображения за счет «доопределенных» пикселей, но и отношение между оценками полученных при использовании различных алгоритмов и методов «доопределения» тонов пикселей. Отношение позволяет ранжировать и оценивать работу алгоритмов относительно друг друга, а также осуществлять выбор при дальнейшем совместном использовании с алгоритмами выделения контуров объектов.

Пример оценок работы алгоритма сбалансированного «доопределения» тонов пикселей. Оценки тоновой девиации пикселей. Для численного анализа алгоритма сбалансированного «доопределения» с критерием минимальной тоновой девиации «доопределяемых» пикселей воспользуемся коллекцией в 1000 растровых RGB изображений, свободно предоставляемой ImageNet (датасет SpaceNet Satellite Images) для машинного обучения в целях образовательного процесса. Для демонстрации различий значений оценок тоновой девиации выполним ее также с целью «доопределения» методом копирования близлежащего смежного пикселя,

как наиболее популярным. Вычисление и оценка тоновой девиации требуют проведения расчета выборочного среднего значения и выборочной дисперсии пикселей из трех ближайших столбцов к «доопределяемому» столбцу пиксельной матрицы растрового изображения, до и после включения в оценку значений из «доопределяемого» столбца. Их расчет проводится для трех RGB компонент в отдельности, а результаты будут описаны в виде векторов $\overline{pel}$ и D трех значений, характеризующих цветовые компоненты: красный pel_r, D_r ; зеленый pel_g, D_g ; синий pel_b, D_b . Пусть $\overline{pel}^{bef}, D^{bef}$ – значение вектора выборочного среднего и выборочной дисперсии тонов пикселей до включения в оценку «доопределенных» значений; $\overline{pel}_{copy}^{aft}, D_{copy}^{aft}$ – значение вектора выборочного среднего и выборочной дисперсии тонов пикселей после

включения в оценку «доопределенных» значений методом заполнения ближайшим смежным значением; $\overline{pel}_{bal}^{aft}, D_{bal}^{aft}$ – значение вектора выборочного среднего и выборочной дисперсии тонов пикселей после включения в оценку «доопределенных» значений алгоритмом сбалансированного «доопределения» с необходимым для этого алгоритма набором весовых коэффициентов $b_1 = 0,25; b_2 = 0,125, c_1 = 0,4; c_2 = 0,15; c_3 = 0,06$, и согласно формульным выражениям, представленным в [4, 5]. Так как расчет оценок проводится для множества растровых изображений, то по множеству полученных выборочных средних и выборочных несмещенных дисперсий тонов пикселей из $i \in [1, 1000]$ изображений будет проведено вычисление их средних арифметических. Результаты представлены в таблице 1.

Таблица 1. Значение среднеарифметических оценок множества выборочных средних и дисперсий тонов пикселей (покомпонентно) для i изображений до и после включения в оценку «доопределенных» значений

i	$\frac{\sum \overline{pel}^{bef}}{i}$	$\frac{\sum D^{bef}}{i}$	$\frac{\sum \overline{pel}_{copy}^{aft}}{i}$	$\frac{\sum D_{copy}^{aft}}{i}$	$\frac{\sum \overline{pel}_{bal}^{aft}}{i}$	$\frac{\sum D_{bal}^{aft}}{i}$
250	$\begin{pmatrix} 203 \\ 96 \\ 72 \end{pmatrix}$	$\begin{pmatrix} 3407 \\ 2757 \\ 3235 \end{pmatrix}$	$\begin{pmatrix} 198 \\ 113 \\ 59 \end{pmatrix}$	$\begin{pmatrix} 3781 \\ 3842 \\ 3534 \end{pmatrix}$	$\begin{pmatrix} 205 \\ 91 \\ 72 \end{pmatrix}$	$\begin{pmatrix} 3398 \\ 2753 \\ 3227 \end{pmatrix}$
500	$\begin{pmatrix} 195 \\ 78 \\ 63 \end{pmatrix}$	$\begin{pmatrix} 3351 \\ 2790 \\ 2202 \end{pmatrix}$	$\begin{pmatrix} 174 \\ 71 \\ 46 \end{pmatrix}$	$\begin{pmatrix} 3751 \\ 3910 \\ 3455 \end{pmatrix}$	$\begin{pmatrix} 195 \\ 77 \\ 65 \end{pmatrix}$	$\begin{pmatrix} 3406 \\ 2710 \\ 2279 \end{pmatrix}$
750	$\begin{pmatrix} 187 \\ 84 \\ 51 \end{pmatrix}$	$\begin{pmatrix} 3320 \\ 2566 \\ 2771 \end{pmatrix}$	$\begin{pmatrix} 190 \\ 89 \\ 42 \end{pmatrix}$	$\begin{pmatrix} 3694 \\ 3922 \\ 2148 \end{pmatrix}$	$\begin{pmatrix} 183 \\ 81 \\ 55 \end{pmatrix}$	$\begin{pmatrix} 3147 \\ 2510 \\ 2680 \end{pmatrix}$
1000	$\begin{pmatrix} 171 \\ 83 \\ 47 \end{pmatrix}$	$\begin{pmatrix} 3271 \\ 2398 \\ 1973 \end{pmatrix}$	$\begin{pmatrix} 184 \\ 86 \\ 59 \end{pmatrix}$	$\begin{pmatrix} 3553 \\ 2806 \\ 2241 \end{pmatrix}$	$\begin{pmatrix} 170 \\ 81 \\ 45 \end{pmatrix}$	$\begin{pmatrix} 3226 \\ 2310 \\ 1935 \end{pmatrix}$

Анализ значений в таблице 1 указывает на то, что средние выборочные значения тонов пикселей, полученные при использовании алгоритма сбалансированного «доопределения», характеризуются меньшим смещением значения относительно тонов пикселей оригинального изображения, чем при использовании метода копирования смежного пикселя. Несмещенная выборочная дисперсия и среднее квадратичное отклонение тонов пикселей у алгоритма сбалансированного «доопределения» пикселей в большинстве случаев меньше, чем у метода копирования ближайшего смежного, т.е. *меньший диапазон разброса значений относительно среднего выборочного тона пикселя*. Для $i = 1000$ изображений значения оценок приращений выборочного среднего тонов пикселей и выборочных дисперсий относительно выборочных средних

$$\Delta \overline{pel}_{copy} = \left| \left(\frac{\sum \overline{pel}^{bef}}{i} \right) - \left(\frac{\sum \overline{pel}_{copy}^{aft}}{i} \right) \right|;$$

$$\Delta \overline{pel}_{bal} = \left| \left(\frac{\sum \overline{pel}^{bef}}{i} \right) - \left(\frac{\sum \overline{pel}_{bal}^{aft}}{i} \right) \right|$$

и выборочных дисперсий

$$\Delta D_{copy} = \left| \left(\frac{\sum D^{bef}}{i} \right) - \left(\frac{\sum D_{copy}^{aft}}{i} \right) \right|;$$

$$\Delta D_{bal} = \left| \left(\frac{\sum D^{bef}}{i} \right) - \left(\frac{\sum D_{bal}^{aft}}{i} \right) \right|$$

после учета «доопределенных» тонов пикселей для алгоритма сбалансированного «доопределения» показывают лучшие результаты по диапазонам колебаний тоновых значений $\Delta \overline{pel}_{bal} = 2$; $\Delta D_{bal} = 83$; $\Delta \sigma_{bal} \approx 9$, при сравнении значений, полученных методом ко-

пирования ближайшего смежного $\overline{\Delta pel_{copy}} = 13$; $\Delta D_{copy} = 408$; $\Delta \sigma_{copy} \approx 20$. Оценки приращений для алгоритма сбалансированного «доопределения» и метода копирования ближайших смежных тонов пикселей попадают в диапазон $\overline{\Delta pel} \approx 15$; $\Delta D \approx 400$; $\Delta \sigma_n \approx 20$, что является удовлетворительным результатом. Это указывает на то, что для алгоритма сбалансированного «доопределения» ошибочные визуальные эффекты не наблюдаются, и работа алгоритмов нелинейной фильтрации по выделению контуров объектов будет осуществлена с минимальной тоновой девиацией и без интерпретации контуров по «мнимым» объектам на границах растрового изображения. Оценка тоновой девиации пикселей на границах изображений для алгоритма сбалансированного «доопределения» тонов пикселей в среднем сокращена в 5 раз относительно метода «доопределения» копированием. Оценка тоновой девиации наглядно демонстрирует разницу в результатах работы анализируемых способов, однако она является специально разработанным критерием

оценки, основанным на статистическом анализе и использующим выборочное среднее, а также выборочную дисперсию «доопределяемых» тонов пикселей.

Заключение

Описанные стандартные методы оценки подвергаются критике и не всегда подходят для оценки изменяемых характеристик растровых изображений и результатов специфических преобразований над ними. Следовательно, целесообразно проводить оценку, используя как стандартные общепринятые критерии, так и собственный разработанный критерий, если он позволяет качественно и наглядно оценить изменения между исходным и обработанным растровым изображением [3]. Представленные критерии могут быть эффективно использованы для оценки результатов работы разработанного сбалансированного алгоритма по критерию изменения тоновой девиации «доопределенных» пикселей [4, 5].

ЛИТЕРАТУРА

1. Оценка качества цифровых изображений и видеоданных / Д. В. Матвеев, А. Г. Седов, В. В. Хрящев, А. Л. Приоров. Ярославль : ЯрГУ, 2018. 76 с.
2. Старовойтов, В. В. Уточнение индекса SSIM структурного сходства изображений / В. В. Старовойтов // Информатика. 2018. Т. 15, № 3. С. 41–55. URL: <https://inf.grid.by/jour/article/view/438/429> (дата обращения: 10.06.2026).
3. Старовойтов, В. В. Индекс SSIM не является метрикой и плохо оценивает сходство изображений / В. В. Старовойтов // Системный анализ и прикладная информатика. 2019. № 2. С. 12–17. DOI: 10.21122/2309-4923-2019-2-12-17.
4. Определение контуров объектов методами не линейной фильтрации для граничных пикселей / Д. В. Заерко, В. А. Липницкий, Н. Л. Боброва, Дм. В. Заерко. Системный анализ и прикладная информатика. 2022. № 3. С. 4–11. DOI: 10.21122/2309-4923-2022-3-4-11.
5. Заерко, Д. В. Алгоритм сбалансированной интерполяции пикселей при выделении контуров объектов на границах изображения / Д. В. Заерко, Н. Л. Боброва // Вестник СибГУТИ. 2022. № 2. С. 79–93. <https://doi.org/10.55648/1998-6920-2022-16-2-79-93>.
6. Bailey, D. G. Image border management for FPGA based filters / D. G. Bailey // 2011 Sixth IEEE International symposium on electronic design, test and application, DELTA 2011, 17–19 January 2011, Queenstown, New Zealand / ed.: G. S. Gupta [et al.]. Los Alamitos ; Washington ; Tokyo, 2011. P. 144–149. DOI: 10.1109/DELTA.2011.34.

REFERENCES

1. Matveev D.V., Sedov A.G., Hryashhev V.V., Priorov A.L. *Ocenka kachestva cifrovyyh izobrazhenij i videodannyh [Assessing the Quality of Digital Images and Video Data]*. Jaroslavl: JarGU; 2018. 76 p.
2. Starovoitov V.V. Enhancement of the structural similarity index SSIM. *Informatics*. 2018;15(3):41–55. Available at: <https://inf.grid.by/jour/article/view/438/429> (accessed 10 June 2026) (in Russian).
3. Starovoitov V.V. The SSIM index is not a metric and it is badly evaluate the similarity of images. *System Analysis and Applied Information Science*. 2019;(2):12–17 (in Russian). <https://doi.org/10.21122/2309-4923-2019-2-12-17>.
4. Zaerko D.V., Lipnitski V.A., Bobrova N.L., Zaerko Dm.V. Objects outline delineation by nonlinear filtration methods for boundary pixels. *System Analysis and Applied Information Science*. 2022;(3):4–11 (in Russian). <https://doi.org/10.21122/2309-4923-2022-3-4-11>.
5. Zaerko D.V., Bobrova N.L. Balanced pixel interpolation algorithm when identifying the object's contours on the borders of the image. *Vestnik SibGUTI*. 2022;(2):79–93 (in Russian). <https://doi.org/10.55648/1998-6920-2022-16-2-79-93>.
6. Bailey D.G. Image border management for FPGA based filters. *2011 Sixth IEEE International Symposium on Electronic Design, Test and Application*. Queenstown, New Zealand; 2011. pp. 144–149. <https://doi.org/10.1109/DELTA.2011.34>.

D. V. ZAEKO¹⁾, N. L. BOBROVA¹⁾, Dm. V. ZAEKO²⁾

-tone deviation evaluation of boundary pixels static raster image using balanced extending algorithms

¹⁾ Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus

²⁾ Yanka Kupala State University of Grodno
Grodno, Republic of Belarus

Abstract. While use algorithms of pre-processing raster image involves improving image characteristics to use qualitative transformation effect result on following processing stages. Assessing the effect of an impact on a raster image is not a trivial task, where the choice of further processing steps and algorithmic tools depends on the quality of its implementation. The algorithm for balanced "extension" of boundary pixels of a static raster image is as example. Algorithm developed to improve the results of object edge detection algorithms based on the two-dimensional convolution operation, where the improvement consists of reducing the number of sharply contrasting pixels at the boundaries of raster images relative to adjacent ones. Existing numerical raster images estimates of PSNR and SSIM which obtained after applying the balanced algorithm of redefining border pixels have shown their low efficiency due to the small number of pixels affected by the transformations. The tonal deviation of raster image boundary pixels is alternative assessment criterion. The object of study in the article is the pixel matrix of three-channel color static raster image. The subject of the study is the evaluation of the tonal deviation of the boundary pixels of a static raster image obtained by used balanced algorithm for redefining border pixels. The main objective is to calculate the tonal deviation estimates of boundary static raster images after applying balanced algorithm of "redefining" border pixels, analysis and ranking by alternative methods of "extension" of boundary sizes according to the criterion of tonal deviation. The article provides a definition of the concept of tonal deviation and justification for the use of tonal deviation assessment. An example of calculating the tonal deviation of pixels after applying the balanced algorithm of "redefining" border pixels and the copy method for 1 thousand color three-channel raster images from the SpaceNet Satellite Images dataset from ImageNet is presented. It was carried out short analysis of the obtained assessment results and recommendations for choosing the best methods of "redefining" border pixels.

Keywords: raster images, pixel matrix, boundary pixels, pixel redefining, outline object segmentation, Sobel filter, SSIM, PSNR, evaluation of tone deviation



Заерко Денис Владимирович

Белорусский государственный университет информатики и радиоэлектроники (БГУИР), г. Минск, Республика Беларусь.


Аспирант кафедры информатики БГУИР. Область научных исследований: машинные алгоритмы распознавания объектов, машинное обучение, анализ данных.

D. V. Zaerko

Belarusian State University of Informatics and Radioelectronics (BSUIR), Minsk, Republic of Belarus.

Postgraduate Student at the Department of Informatics, BSUIR. Research interests: machine object recognition algorithms, machine learning, data analysis.

E-mail: zaerko1991@gmail.com



Боброва Наталия Леонидовна

Белорусский государственный университет информатики и радиоэлектроники (БГУИР), г. Минск, Республика Беларусь.

Кандидат технических наук, доцент кафедры информатики БГУИР. Область научных исследований: прикладная логика, нечеткие множества, система поддержки принятия решений.

N. L. Bobrova

Belarusian State University of Informatics and Radioelectronics (BSUIR), Minsk, Republic of Belarus.

PhD in Technical Sciences, Associate Professor at the Department of Informatics, BSUIR. Research interests: applied logic, fuzzy sets, decision support systems.

E-mail: bobrova@bsuir.by

**Заерко Дмитрий Владимирович**

Гродненский государственный университет имени Янки Купалы (ГрГУ им. Я. Купалы), г. Гродно, Республика Беларусь.

Кандидат физико-математических наук, доцент кафедры электротехники и электроники ГрГУ им. Я. Купалы. Область научных интересов: радиофизика, радиоэлектроника, взаимодействия электромагнитного излучения с периодическими структурами и композиционными материалами.

Dm. V. Zaerko

Yanka Kupala State University of Grodno, Republic of Belarus.

PhD in Physics and Mathematics, Associate Professor at the Department of Electrical Engineering and Electronics. Research interests: radiophysics, radioelectronics, interaction of electromagnetic radiation with periodic structures and composite materials.

E-mail: zaerko1983@gmail.com

Ю. И. ГОЛУБ¹⁾, М. М. ЛУКАШЕВИЧ^{1, 2)}, В. В. СТАРОВОЙТОВ¹⁾

ПРОТОТИП СИСТЕМЫ УДАЛЕННОГО АВТОМАТИЗИРОВАННОГО СКРИНИНГА ДИАБЕТИЧЕСКОЙ РЕТИНОПАТИИ

¹⁾ Объединенный институт проблем информатики Национальной академии наук Беларуси
г. Минск, Республика Беларусь

²⁾ Белорусский государственный университет
г. Минск, Республика Беларусь

Аннотация. В статье представлены результаты разработки и тестирования прототипа автоматизированной системы удаленного скрининга диабетической ретинопатии (ДР) с функциями предобработки и классификации цифровых изображений, полученных фундус-камерами разных производителей. Экспериментальное тестирование прототипа выполнено на нескольких тысячах реальных изображений из белорусских медицинских учреждений и открытых источников. Объективная оценка качества изображения сетчатки вычисляется посредством анализа центрального фрагмента на базе параметра масштаба распределения Вейбулла для локальных оценок качества зеленого канала изображения. Прототип разработан на платформе Streamlit, использует нейросетевые архитектуры YOLOv8 и YOLOv11 для классификации пяти стадий ДР, точность классификации составила 84,0 % и 82,7 % соответственно. Комбинация фильтрации некачественных снимков и нейросетевой классификации повышает достоверность скрининговой диагностики и может быть использована в телемедицинских системах, имеющих ограниченные вычислительные ресурсы.

Ключевые слова: диабетическая ретинопатия, безэталонная оценка качества, распределение Вейбулла, Streamlit, YOLO, удаленный скрининг, классификация изображений сетчатки

Введение

Сахарный диабет относится к числу наиболее распространенных неинфекционных заболеваний и является значимой проблемой. Согласно данным Всемирной организации здравоохранения (ВОЗ), в период с 1980 по 2014 год число людей с диагнозом «сахарный диабет» увеличилось с 108 миллионов до 422 миллионов человек [1, 2]. На начало 2025 года в Беларуси под медицинским наблюдением состояло более 407 600 пациентов с сахарным диабетом. В Минске распространенность заболевания за десятилетие (с 2014 по 2024 год) выросла вдвое: с почти 2,3 тыс. до почти 4,6 тыс. случаев на 100 тыс. населения [3]. К осложнениям диабета относят диабетическую ретинопатию. Это заболевание может начинаться абсолютно бессимптомно. У многих людей симптомы могут не проявиться до тех пор, пока заболевание не начнет прогрессировать в более тяжелые стадии, в таком случае это приводит к лишению зрения и слепоте. Во всем мире среди причин слепоты ДР занимает пятое место. Офтальмологическое обследование, которое должен проходить каждый заболевший сахарным диабетом, позволяет выявить появление и развитие ДР на ранней стадии, что позволяет, при дальнейшем лечении, остановить или замедлить потерю зрения. По данным итогового отчета работы эндокринологической службы Республики Беларусь в 2021 году одна из причин роста числа заболевших ДР – это недостаточное выявление заболевания на ранних стадиях [4].

В настоящее время во многих странах наблюдается рост числа людей с диабетом, что создает

дополнительную нагрузку на службы здравоохранения. В связи с чем внедряются автоматизированные системы, которые выявляют пациентов с риском ДР, которые нуждаются в дальнейшем обследовании [1, 5–7]. Например, в Шотландии с 2003 года действует централизованная программа скрининга ДР. В 2007 году в Финляндии стартовал проект, направленный на повышение доступности обследований на ДР. В рамках проекта был использован мобильный офтальмологический пункт. В Норвегии была создана программа скрининга диабетической ретинопатии, в рамках которой снимки сетчатки, полученные в местных медучреждениях и оптиках, передаются в центр, где специалисты могут оценить их в 4–5 раз больше, чем при обычном осмотре. В Испании в рамках программ скрининга ДР специально обученный персонал делает снимки глазного дна с помощью цифровых камер и отправляет данные врачам для оценки.

Использование автоматизированных систем для анализа изображений глазного дна повышает доступность и эффективность массового скрининга диабетической ретинопатии [8]. Ранняя диагностика и регулярный мониторинг состояния сетчатки являются ключевыми этапами для предотвращения необратимой слепоты. Система удаленного скрининга диабетической ретинопатии позволяет автоматизировать процесс анализа офтальмологических изображений, повысить доступность диагностики и снизить нагрузку на специалистов. В настоящее время наблюдается недостаток офтальмологов в отдаленных регионах развивающихся стран (например, в Индии), существует

высокая нагрузка на специалистов, а также неравномерное распределение оборудования в медицинских учреждениях. Основными пользователями автоматизированной системы могут быть врачи-офтальмологи, терапевты и эндокринологи, медицинский персонал поликлиник и диспансеров.

Данная работа обобщает результаты исследований, нацеленных на создание прототипа экспериментальной автоматизированной системы удаленного скрининга ДР по изображениям сетчатки глаза, зарегистрированным произвольной фундус-камерой в видимом диапазоне электромагнитного спектра. Более подробно результаты выполненных исследований изложены в работах [9–12].

1. Объективная оценка качества цифровых изображений сетчатки

Качество фундус-изображений может снижаться из-за движений или моргания пациента во время съемки, а также из-за неправильной настройки камеры. Это приводит к размытию, бликам, низкой контрастности или неравномерной яркости снимков. Для определения стадии диабетической ретинопатии нужны резкие и яркие изображения сетчатки без посторонних объектов. Оценка качества изображений глазного дна является первым и критически важным этапом в любой автоматизированной системе диагностики ДР. Без отбраковки некачественных снимков даже самые совершенные нейросетевые классификаторы будут давать нестабильные результаты. Оценку качества можно выполнять на этапе регистрации снимков.

Для экспериментальных исследований была сформирована база реальных изображений сетчатки, включающая снимки из белорусских медицинских учреждений и общедоступных источников.

Фундус-камеры формируют цветные изображения, которые можно разложить на RGB-каналы (красный, зеленый, синий). Результаты экспериментального анализа показали, что зеленый канал обеспечивает максимальную контрастность сосудистого рисунка и наиболее эффективное выявление микроаневризм. Красный канал – чрезмерно светлый, а синий – слишком темный, что снижает их диагностическую ценность. Поэтому для оценки качества используется полутонное изображение, полученное из зеленого канала.

Для снимков с неоднородным фоном затруднительно получать бинарную маску поля зрения (FOV – field of view), поэтому предложено выделять центральную область сетчатки (ЦОС). Экспериментально установлено, что оптимальный размер ЦОС составляет 50–67 % от ширины исходного изображения в зависимости от угла обзора камеры. Для белорусских данных (3608×3608 и 2448×2448 пикселей) ЦОС со стороной 0,67 исходного размера позволяет надежно разделять снимки на удовлетворительные и неудовлетворительные, тогда как меньшая ЦОС (0,5) оказалась недостаточно точной.

Было исследовано 36 функций, используемых для оценки качества без эталонного изображения (ACMO, BEGH, BREN, BRISQUE, CONT, CURV, EBCM, FFT, FISH, FUS, GLLV, GLVM, GOLE, GORD, GRAE, GRAT, HELM, JNBM, KADN, KURT, LAPD, LAPL, LAPM, LOCC, LOEN, MLV, NIQE, PIQE, PSIS, SHAR, STDK, SVDB, TENG, VOLA, WAVS). Они вычислялись локально для каждого изображения сетчатки. Использование в качестве глобальных оценок среднего, медианы и стандартного отклонения показали сильное перекрытие между классами качества. Поскольку распределение локальных оценок качества на реальных изображениях часто не соответствует нормальному, для обобщения использованы параметры распределения Вейбулла – масштаб (scale) и форма (form), а также среднее нормального распределения (mean) для сравнения. Параметр scale для функций FUS и TENG показал монотонный рост с улучшением качества изображения и позволил установить порог разделения на два класса. Параметры form и mean – менее информативны.

Для унификации и ускорения обработки ЦОС масштабируется до фиксированного размера 512×512 пикселей. Коэффициент корреляции Пирсона между оценками для исходной и масштабированной ЦОС составил 0,9946 (scale FUS), 0,9707 (form) и 0,9520 (mean). Функции FUS и TENG сохранили высокую корреляцию (>0,98), тогда как другие оценки (например, BISH, NIQE, HELM) показали снижение ниже 0,7. Визуальный контроль подтвердил, что при размере 512×512 пикселей сохраняются диагностически значимые детали (микроаневризмы, сосуды). Дальнейшее уменьшение размера приводит к потере точности.

На заключительном этапе глобальная оценка качества Q сравнивается с порогом tr , который подбирается экспериментально для конкретной базы данных или типа камеры. Если $Q > tr$, изображение признается удовлетворительного качества и допускается к дальнейшему диагностическому анализу; в противном случае снимок отбраковывается с рекомендацией повторной съемки.

Подробно результаты исследования оценки качества изображений сетчатки и предлагаемый метод представлены в статье [12]. Предложенный метод протестирован на 3170 изображениях (белорусские клинические данные, Aptos2019 [13], DDR [8]). Ограничение метода является необходимостью индивидуальной настройки порога tr для каждой конкретной базы данных и типа камеры. Для 327 изображений из общедоступной базы Kaggle точность (accuracy) оценки качества исходного изображения сетчатки (при использовании зеленого канала и ЦОС 512×512 пикселей) достигла 0,966, что на 40 % выше, чем при анализе полного изображения (0,691). Обработка центральной области размером 512×512 пикселей требует в 20 раз меньше времени для вычисления локальных оценок по сравнению с анализом полного кадра (размером 3608×3608 пикселей). На рисунке 1 представлен результат разделения изображений сетчатки на два класса с применением разработанного метода безэталонной количественной оценки качества.




Рисунок 1. Примеры изображений двух классов качества

2. Обзор существующих систем автоматизированного скрининга диабетической ретинопатии

На сегодняшний день известно несколько систем автоматизированного скрининга ДР.

1) IDx-DR (IDx Technologies) – первая система, одобренная FDA (Food and Drug Administration, управление по санитарному надзору за качеством пищевых продуктов и медикаментов США) для автономной диагностики ДР [5]. Она использует глубокие нейронные сети, отличается высокой стоимостью и требовательностью к качеству изображений. Авторские права на исходные коды принадлежат спонсору и недоступны другим пользователям.

2) Google DeepMind – подразделение компании Google, специализирующееся на разработке систем искусственного интеллекта (ИИ) [5, 14]. В рамках направления Google Health DeepMind создала продвинутые нейросетевые алгоритмы для диагностики глазных заболеваний, включая диабетическую ретинопатию. Google сотрудничает с медицинскими учреждениями и государственными службами здравоохранения (например, Национальная служба здравоохранения в Великобритании) для клинических испытаний и внедрения технологии.

3) Optos Automated AI – инструменты ИИ для анализа изображений сетчатки, помогающие в диагно-

стике различных глазных заболеваний [14].

4) EyeArt AI – коммерческая система для массового скрининга [14], но она дает ошибки классификации при анализе снимков низкого качества и зависима от типа оборудования регистрирующего изображения сетчатки.

Открытые модели (например, на базе Kaggle EyePACS) – можно гибко изменять, но они требуют значительных вычислительных ресурсов и экспертизы для адаптации.

Аналогов с доступными кодами и пригодных для внедрения не имеется.

Ограничения и проблемы существующих решений

Существующие системы автоматизированного скрининга диабетической ретинопатии имеют ряд ограничений:

- зависимость от качества исходных изображений и условий съемки;
- ограниченная интеграция с локальными медицинскими системами;
- высокие требования к вычислительным мощностям;
- для сторонних разработчиков и организаций доступ к исходному коду или моделям ограничен;
- коммерческое использование сопровождается

значительными финансовыми затратами и предполагает обязательное прохождение процедур согласования, лицензирования, а также строгого соблюдения действующих юридических и этических требований.

Таким образом, несмотря на значительный прогресс в области автоматизированного анализа изображений сетчатки, актуальными остаются задачи повышения устойчивости алгоритмов к вариациям качества изображений и снижения стоимости систем для расширения их применения в массовом скрининге диабетической ретинопатии, особенно в регионах с ограниченными ресурсами [14, 15].

3. Прототип системы удаленного автоматизированного скрининга диабетической ретинопатии

Для разработки прототипа автоматизированной системы скрининга ДР были выполнены следующие работы: проанализированы медицинские требования; выбран набор технологий и составлено техническое задание; сформирована база изображений глазного дна с разметками из общедоступных источников; выполнен сбор данных в белорусских медицинских учреждениях при взаимодействии с медицинскими специалистами; выполнены обучение нейросетевых алгоритмов, проверка и тестирование точности классификации стадий ДР; создано веб-приложение для скрининга стадий ДР.

Разработанная система удаленного автоматизированного скрининга ДР решает следующие задачи: автоматический анализ изображений глазного дна и классификация стадий диабетической ретинопатии. Архитектура системы включает в себя следующие модули: модуль сбора данных, который предполагает загрузку изображений через веб-интерфейс; модуль количественной оценки качества изображений (реализованная по описанной выше схеме); модуль предварительной обработки изображений (три варианта: Standard, CLAHE, Green channel); модуль детекции ДР и классификации стадий ДР с использованием нейронных сетей; модуль формирования отчета; модуль хранения и управления данными. Система реализована на языке Python с использованием фреймворка Streamlit, использование которого обеспечивает создание интерактивного и визуально удобного веб-интерфейса для работы с меди-

цинскими изображениями, а также ускоряет процесс прототипирования. Функционирование моделей глубокого обучения обеспечивается высокопроизводительной архитектурой, которая поддерживает использование как центрального процессора (ЦП), так и специализированного графического процессора (ГП). Такая архитектура позволяет оптимизировать вычислительные процессы и существенно ускоряет обработку данных, что особенно важно при работе с ресурсоемкими задачами. Для работы на ГП требуется среда CUDA (Compute Unified Device Architecture) и библиотека cuDNN.

Поддерживаются форматы изображений JPG и PNG. Пользователь может загрузить снимок (рисунки 2–3), оценить его качество, выбрать метод предобработки (рисунок 4) и запустить скрининг. Результат включает информацию о стадии ретинопатии и визуализацию областей интереса (рисунки 4–5).

Пользователю доступны следующие методы предварительной обработки изображения:

1) Standard – базовый, т.е. без применения дополнительных алгоритмов улучшения;

2) CLAHE (Contrast Limited Adaptive Histogram Equalization) – алгоритм адаптивного выравнивания гистограммы с ограничением контраста, позволяющий улучшить детализацию слабо освещенных областей изображения;

3) Green – алгоритм, основанный на извлечении зеленого цветового канала из цветного изображения. Поскольку зеленый канал содержит наибольший контраст и меньше шумов по сравнению с красным и синим, его использование повышает качество визуализации сосудистой сети и других анатомических структур сетчатки.

После выбора необходимого алгоритма обработки пользователь запускает процесс скрининга. Система осуществляет анализ изображения с применением выбранного алгоритма и проводит комплексную оценку состояния сетчатки. По завершении процесса скрининга пользователь получает доступ к результатам анализа, включающим стадию ретинопатии и области интереса, требующие дополнительного внимания. Визуализация результатов представлена в удобном для интерпретации виде, что позволяет врачу оперативно оценить состояние пациента и принять необходимые меры.




Рисунок 2. Интерфейс приложения при запуске, обеспечивающий пользователю доступ к основным функциональным модулям системы




Рисунок 3. Пример загрузки изображения для последующего анализа

Интерфейс вывода результатов после выполнения скрининга представлен на рисунке 4, где отображаются области интереса, требующие дополнительного внимания (рисунок 5). Система автоматически выделяет потенциально патологические участки сетчатки, что позволяет врачу оперативно оценить состояние пациента и принять необходимые меры для дальнейшего лечения.




Рисунок 4. Выполнение скрининга. Заключение системы по стадиям диабетической ретинопатии



Рисунок 5. Визуализация областей интереса на изображении глазного дна, важных для клинической интерпретации и подтверждения диагноза

4. Нейросетевые модели классификации диабетической ретинопатии и их тестирование

Для классификации стадий ДР (5 классов: от отсутствия заболевания до пролиферативной ретинопатии) использованы две архитектуры семейства YOLO – YOLOv8 и YOLOv11. Обучение проводилось на комбинации общедоступных наборов данных и изображениях, собранных в белорусских медицинских учреждениях.

Суммарно YOLOv8n-cls включает 73 слоя, 1 441 285 параметров. Точность (accuracy) на тестовом наборе данных равна 84 %. Скорость предварительной обработки – 0,6 мс на ГП, скорость инференса (получения результатов классификации) – 1,3 мс на ГП.

Суммарно YOLOv11n-cls включает 112 слоев, 1 532 429 параметров. Точность (accuracy) на тестовом наборе данных равна 82,7 %. Скорость предварительной обработки 0,7 мс на ГП, скорость инференса – 1,3 мс на ГП.

Ошибки классификации преимущественно возникают между смежными или схожими классами (например, объекты класса 1 ошибочно отнесены к классу 2).

Тестирование производительности системы выполнялось в следующей среде: ГП – NVIDIA GeForce RTX 4090 (24GB GDDR6X), ЦП: Intel Core i9-13900K, оперативная память: 64GB DDR5. Размер изображений был от 819x640 до 2588x1958 пикселей. Всего было использовано для тестирования порядка 2000 изображений.

Усредненные оценки производительности (полный анализ, обработка и классификация одного изображения) с использованием ЦП следующие:

- загрузка изображения от 130 до 160 мс;
 - оценка качества изображения от 50 до 60 мс;
 - предварительная обработка (CLAHE) от 200 до 240 мс;
 - классификация с использованием модели нейронной сети: от 100 до 120 мс;
 - отображение результатов: от 100 до 110 мс.
- Итого: от 580 до 690 мс.

Использование ГП в части классификации позволяет ускорить работу приложения. Основным временным вкладом на ЦП вносит предобработка CLAHE (200–240 мс). Многопользовательский режим функционирования приложения не тестировался.

5. Практическое использование результатов исследования и изучение перспектив дальнейшего развития

Разработанный прототип системы удаленного скрининга диабетической ретинопатии может применяться в первичном звене здравоохранения для массового скрининга и раннего выявления заболевания, а также в телемедицинских центрах – для дистанционной диагностики и мониторинга состояния сетчатки. Кроме того, ее можно использовать в офтальмологических клиниках для углубленной диагностики и наблюдения за пациентами с разными стадиями ДР, а в научных исследованиях – для анализа эффективности методов диагностики и лечения.

В результате исследования перспектив дальнейшего развития определены возможные направления для углубления и расширения результатов данной работы:

1) исследование влияния различных параметров обработки и анализа изображения на точность диагно-

стики: проведение детального анализа и систематизации факторов, влияющих на качество и достоверность диагностических результатов;

2) расширение функциональности системы за счет внедрения дополнительных алгоритмов предварительной обработки, оценки качества и разметки данных:

- разработка и интеграция новых методов предварительной обработки изображений, направленных на улучшение качества данных перед их анализом;

- доработка приложения для разметки изображений сетчатки офтальмологом;

3) улучшение точности диагностики путем совершенствования методов МО:

- исключение возможных ошибок в процессе разметки данных;

- балансировка классов в обучающей выборке;

- дополнительный анализ признаков для повышения информативности моделей;

- доработка архитектуры моделей МО с целью улучшения межклассовой разделимости;

4) интеграция с существующими медицинскими информационными системами: адаптация разработанного ПО к специфике локальных данных, требованиям телемедицинских платформ, к работе с большими объемами данных;

5) оптимизация производительности и повышение скорости анализа изображения для обеспечения функционирования приложения в режиме реального времени;

6) разработка мультимодальных алгоритмов за счет сочетания анализа изображений фундус-камеры с данными оптической когерентной томографии для повышения точности и полноты диагностики;

7) разработка мобильной версии приложения для обеспечения доступности системы диагностики в различных условиях.

Заключение

Регулярный скрининг позволяет выявить заболевание на ранних стадиях, однако дефицит офтальмологов, неравномерное распределение оборудования и высокая нагрузка на специалистов ограничивают доступность диагностики, особенно в удаленных регионах. Автоматизированные системы анализа изображений глазного дна на основе методов машинного обучения могут решить эту проблему, но их эффективность критически зависит от качества входных снимков.

Объединение разработанного метода оценки качества и системы нейросетевой классификации позволяет создать автоматизированный процесс скрининга ДР.

Разработан, реализован и протестирован прототип системы удаленного автоматизированного скрининга диабетической ретинопатии по цифровым изображениям сетчатки.

Основные результаты проекта:

1) предложен метод безэталонной количественной оценки качества изображений сетчатки с использованием зеленого канала, центрального фрагмента снимка площадью порядка 50–67 %, локальных функций FUS/TENG, параметра масштаба распределения Вейбулла и масштабирования до 512×512 пикселей;

2) разработан и протестирован экспериментальный прототип системы удаленного скрининга ДР на платформе Streamlit, состоящий из шести модулей, который поддерживает три метода предобработки данных;

3) использованы нейросетевые модели YOLOv8 и YOLOv11, они показали точность классификации стадий ДР 84,0 % и 82,7 % соответственно.

Комбинация отбраковки некачественных снимков и последующей глубокой нейросетевой классификации повышает достоверность скрининга и может быть внедрена в телемедицинские системы, особенно в регионах с ограниченными вычислительными ресурсами и дефицитом офтальмологов.

Исследование выполнено в рамках проекта № Ф23ИНДГ-004.

Вклад авторов

Ю. И. Голуб: подготовка текста статьи и интерпретация результатов экспериментов; подготовка, предварительная обработка и оценка качества изображений сетчатки; проведение сравнительных экспериментов; выполнение обзора существующих решений по автоматизированной диагностике диабетической ретинопатии.

М. М. Лукашевич: подготовка текста статьи и интерпретация результатов экспериментов; разработка и оптимизация архитектуры нейронных сетей для сегментации патологических признаков на изображениях сетчатки; тестирование различных конфигураций гиперпараметров; сравнительные эксперименты по оценке эффективности моделей.

В. В. Старовойтов: организация сбора и разметки данных в медицинских учреждениях, планирование исследований, подготовка текста статьи, интерпретации результатов экспериментов.

ЛИТЕРАТУРА

1. Скрининг на диабетическую ретинопатию: краткое руководство : повышение эффективности, максимальное увеличение пользы и минимизация вреда / Всемирная организация здравоохранения. Европейское региональное бюро. Копенгаген, 2021. 95 с. URL: <https://iris.who.int/handle/10665/340770> (дата обращения: 10.04.2026).
2. Causes of blindness and vision impairment in 2020 and trends over 30 years, and prevalence of avoidable blindness in relation to VISION 2020: the Right to Sight: an analysis for the Global Burden of Disease Study Steinmetz / GBD 2019 Blindness and Vision Impairment Collaborators; Vision Loss Expert Group of the Global Burden of Disease Study // *The Lancet Global Health*. Vol. 9, № 2. P. e144–e160.
3. Сколько пациентов с сахарным диабетом находятся под меднаблюдением в Беларуси, рассказала эндокринолог // БЕЛТА. URL: <https://belta.by/society/view/skolko-patsientov-s-saharnym-diabetom-nahodjatsja-pod-mednabljudeniem-v-belarusi-rasskazala-746976-2025/>. Дата публ.: 04.11.2025.
4. Лукашевич, М. М. Классификация стадий диабетической ретинопатии на основе нейронных сетей / М. М. Лукашевич, Ю. И. Голуб // *Системный анализ и прикладная информатика*. 2022. № 3. С. 12–21. DOI: 10.21122/2309-4923-2022-3-12-21.
5. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices / M. D. Abramoff, P. T. Lavin, M. Birch [et al.] // *NPJ digital medicine*. 2018. Vol. 1. P. 39. DOI: 10.1038/s41746-018-0040-6.
6. Scanlon, P. H. The English National Screening Programme for diabetic retinopathy 2003–2016 / P. H. Scanlon // *Acta diabetologica*. 2017. Vol. 54. P. 515–525. DOI: 10.1007/s00592-017-0974-1.
7. Diabetic retinopathy screening: global and local perspective / R. A. Gangwani, J. X. Lian, Sarah M. McGhee [et al.] // *Hong Kong Medical Journal*. 2016. Vol. 22, № 5. P. 486–495. DOI: 10.12809/hkmj164844.
8. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening / T. Li, Y. Gao, K. Wang [et al.] // *Information Sciences*. 2019. Vol. 501. P. 511–522. DOI: 10.1016/j.ins.2019.06.011.
9. Golub, Y. Retinal Image Analysis Approach for Diabetic Retinopathy Grading / Y. Golub, M. Lukashevich, V. Starovoitov // *Pattern Recognition and Information Processing*. Springer, Cham, 2022. Vol. 1562. P. 152–165. DOI: 10.1007/978-3-030-98883-8_11.
10. Starovoitov, V. A universal retinal image template for automated screening of diabetic retinopathy / V. V. Starovoitov, Yu. I. Golub, M. M. Lukashevich // *Pattern Recognition and Image Analysis*. 2022. Vol. 32, № 2. P. 322–331. DOI: 10.1134/S1054661822020195.
11. Классификации стадий диабетической ретинопатии на основе алгоритмов машинного обучения и набора признаков / М. М. Лукашевич, Ю. И. Голуб, В. В. Старовойтов // *Информационные системы и технологии = Information Systems and Technologies : материалы междунар. науч. конгресса по информатике*, 27–28 окт.

2022 г., Респ. Беларусь, Минск : в 3 ч. / Белорус. гос. ун-т ; редкол.: С. В. Абламейко (гл. ред.) [и др.]. Минск, 2022. Ч. 2. С. 169–176.

12. Голуб, Ю. И. Объективная оценка качества цифровых изображений сетчатки при скрининговом исследовании / Ю. И. Голуб, В. В. Старовойтов // Системный анализ и прикладная информатика. 2025. № 3. С. 47–58. DOI: 10.21122/2309-4923-2025-3-47-58.

13. APTOS 2019 Blindness Detection / Kaggle. 2019. URL: <https://www.kaggle.com/c/aptos2019-blindness-detection> (date of access: 10.04.2026).

14. Diabetic retinopathy screening through artificial intelligence algorithms: A systematic review / Z. Farahat, N. Zrira, N. Souissi [et al.] // Survey of Ophthalmology. 2024. Vol. 69, № 5. P. 707–721. DOI: 10.1016/j.survophthal.2024.05.008.

15. Павлов, В. Г. Современные тенденции скрининга диабетической ретинопатии / В. Г. Павлов, А. Л. Сидамонидзе, Д. В. Петрачков // Вестник офтальмологии. 2020. Т. 136, № 4. С. 300–309. DOI: 10.17116/oftalma2020136042300.

REFERENCES

1. World Health Organization. Regional Office for Europe. *Diabetic retinopathy screening: a short guide: Increase effectiveness, maximize benefits and minimize harm*. 2020. Available at: <https://iris.who.int/handle/10665/336660> (accessed 10 April 2026).

2. GBD 2019 Blindness and Vision Impairment Collaborators; Vision Loss Expert Group of the Global Burden of Disease Study. Causes of blindness and vision impairment in 2020 and trends over 30 years, and prevalence of avoidable blindness in relation to VISION 2020: the Right to Sight: an analysis for the Global Burden of Disease Study. *Lancet Global Health*. 2021;9(2):e144–e160. [https://doi.org/10.1016/S2214-109X\(20\)30489-7](https://doi.org/10.1016/S2214-109X(20)30489-7).

3. Skol'ko patsientov s sakharnym diabetom nakhodyatsya pod mednablyudeniem v Belarusi, rasskazala ehndokrinolog [How many patients with diabetes mellitus are under medical supervision in Belarus, the endocrinologist said]. *BELTA*. Available at: <https://belta.by/society/view/skolko-patsientov-s-saharnym-diabetom-nahodjatsja-pod-mednabljudeniem-v-belarusi-rasskazala-746976-2025/> (accessed 10 April 2026) (in Russian).

4. Lukashevich M.M., Golub Y.I. Classification of diabetic retinopathy stages based on neural networks. *System Analysis and Applied Information Science*. 2022;(3):12–21 (in Russian). <https://doi.org/10.21122/2309-4923-2022-3-12-21>.

5. Abràmoff M.D., Lavin P.T., Birch M., Shah N., Folk J.C. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *npj Digital Medicine*. 2018;1:39. <https://doi.org/10.1038/s41746-018-0040-6>.

6. Scanlon P.H. The English National Screening Programme for diabetic retinopathy 2003–2016. *Acta Diabetologica*. 2017;54:515–525. <https://doi.org/10.1007/s00592-017-0974-1>.

7. Gangwani R.A., Lian J.X., McGhee S.M., Wong D., Li K.K.W. Diabetic retinopathy screening: global and local perspective. *Hong Kong Medical Journal*. 2016;22(5):486–495. <http://dx.doi.org/10.12809/hkmj164844>.

8. Li T., Gaoet Y., Wang K., Guo S., Liu H., Kang H. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening. *Information Sciences*. 2019;501:511–522. <https://doi.org/10.1016/j.ins.2019.06.011>.

9. Golub Y., Lukashevich M., Starovoitov V. Retinal image analysis approach for diabetic retinopathy grading. *Pattern Recognition and Information Processing. PRIP 2021. Communications in Computer and Information Science*, vol. 1562. Springer, Cham; 2022. p. 152–165. https://doi.org/10.1007/978-3-030-98883-8_11.

10. Starovoitov V.V., Golub Yu.I., Lukashevich M.M. A universal retinal image template for automated screening of diabetic retinopathy. *Pattern Recognition and Image Analysis*. 2022;32:322–331. <https://doi.org/10.1134/S1054661822020195>.

11. Lukashevich M.M., Golub Yu.I., Starovoitov V.V. Klassifikacii stadij diabeticheskoy retinopatii na osnove algoritmov mashinnogo obucheniya i nabora priznakov [Classifications of diabetic retinopathy stages based on machine learning algorithms and feature set]. *Informacionnye sistemy i tehnologii = Information Systems and Technologies : materialy mezhdunar. nauch. kongressa po informatike [Proceedings of the International Scientific Congress on Informatics]*, 27–28 Oct. 2022, Republic of Belarus, Minsk. In 3 parts. Part 2. Minsk; 2022. p. 169–176 (in Russian).

12. Golub Yu.I., Starovoitov V. Objective quality assessment of digital retinal images in screening study. *System Analysis and Applied Information Science*. 2025;(3):47–58 (in Russian). <https://doi.org/10.21122/2309-4923-2025-3-47-58>.

13. APTOS 2019 Blindness Detection. *Kaggle*. 2019. Available at: <https://www.kaggle.com/c/aptos2019-blindness-detection> (accessed 10 April 2026).

14. Farahat Z., Zrira N., Souissi N., Belmekki M., Ngote M.N., Megdiche K., et al. Diabetic retinopathy screening through artificial intelligence algorithms: A systematic review. *Survey of Ophthalmology*. 2024;69(5):707–721. <https://doi.org/10.1016/j.survophthal.2024.05.008>.

15. Pavlov V.G., Sidamonidze A.L., Petrachkov D.V. Current trends in the screening for diabetic retinopathy. *Russian Annals of Ophthalmology*. 2020;136(4):300–309 (in Russian). <https://doi.org/10.17116/oftalma2020136042300>.

Y. I. GOLUB¹⁾, M. M. LUKASHEVICH^{1, 2)}, V. V. STAROVOITOV¹⁾

PROTOTYPE OF A REMOTE AUTOMATED SCREENING SYSTEM FOR DIABETIC RETINOPATHY

¹⁾ United Institute of Informatics Problems of the National Academy of Sciences of Belarus

Minsk, Republic of Belarus

²⁾ Belarusian State University

Minsk, Republic of Belarus

Abstract. The article presents the results of the development and testing of a prototype automated system for remote screening of diabetic retinopathy (DR), featuring preprocessing and classification functionalities for digital images acquired by fundus cameras from various manufacturers. Experimental testing of the prototype was performed on several thousand real-world images from Belarusian medical institutions and open-access sources. Objective assessment of retinal image quality is computed through analysis of the central fragment based on the Weibull distribution scale parameter applied to local quality estimates of the green channel of the image. The prototype was developed on the Streamlit platform and employs the YOLOv8 and YOLOv11 neural network architectures for classifying five stages of DR, achieving classification accuracy of 84.0 % and 82.7 %, respectively. The combination of low-quality image filtering and neural network-based classification enhances the reliability of screening diagnostics and can be deployed in telemedicine systems with limited computational resources.

Keywords: diabetic retinopathy, no-reference image quality assessment, Weibull distribution, Streamlit, YOLO, remote screening, retinal image classification



Голуб Юлия Игоревна

Объединенный институт проблем информатики Национальной академии наук Беларуси (ОИПИ НАН Беларуси), г. Минск, 220012, Республика Беларусь.

Кандидат технических наук, доцент, ведущий научный сотрудник ОИПИ НАН Беларуси. Сфера научных интересов: цифровая обработка изображений и анализ их качества.

Yuliya I. Golub

United Institute of Informatics Problems of the National Academy of Sciences of Belarus (UIIP NAN Belarus), Minsk, 220012, Republic of Belarus.

PhD of Engineering Sciences, Associate Professor, Leading Researcher at the United Institute of Informatics Problems of the National Academy of Sciences of Belarus. Research interests: digital image processing and image quality assessment.



Лукашевич Марина Михайловна

Белорусский государственный университет.

Объединенный институт проблем информатики Национальной академии наук Беларуси (ОИПИ НАН Беларуси), г. Минск, 220012, Республика Беларусь.

Кандидат технических наук, доцент, доцент кафедры информационных систем управления Белорусского государственного университета. Старший научный сотрудник ОИПИ НАН Беларуси. Сфера научных интересов: цифровая обработка изображений и машинное обучение.

Marina M. Lukashevich

Belarusian State University, Minsk, Republic of Belarus.

United Institute of Informatics Problems of the National Academy of Sciences of Belarus (UIIP NAN Belarus), Minsk, 220012, Republic of Belarus.

PhD of Engineering Sciences, Associate Professor at the Department of Information Systems and Technologies, Belarusian State University; Senior Researcher at the United Institute of Informatics Problems of the National Academy of Sciences of Belarus. Research interests: digital image processing and machine learning.

**Старовойтов Валерий Васильевич**

Объединенный институт проблем информатики Национальной академии наук Беларуси (ОИПИ НАН Беларуси), г. Минск, 220012, Республика Беларусь.

Доктор технических наук, профессор. Главный научный сотрудник ОИПИ НАН Беларуси. Лауреат Государственной премии Республики Беларусь (2003 г.). Сфера научных интересов: обработка и анализ данных, представленных в виде цифровых изображений, полученных в разных участках электромагнитного спектра. Опубликовал более 170 научных работ.

Valery Starovoitov

United Institute of Informatics Problems of the National Academy of Sciences of Belarus (UIIP NAS Belarus), Minsk, 220012, Republic of Belarus.

Doctor of Sciences and Professor of Computer Science. He is a Principal Research Fellow at the United Institute of Informatics Problems of the National Academy of Sciences of Belarus. Award: State Prize of the Republic of Belarus in science. Research interests: processing and analysis of digital image data obtained in various regions of the electromagnetic spectrum. He has published over 170 papers.

<https://orcid.org/0000-0001-7190-761X>

В. А. ВИШНЯКОВ

МОБИЛЬНАЯ СИСТЕМА С ЦИФРОВЫМ ДВОЙНИКОМ ДЛЯ ДИАГНОСТИКИ И ПОДДЕРЖКИ ТЕРАПИИ ПАЦИЕНТОВ С НЕВРОЛОГИЧЕСКИМИ ЗАБОЛЕВАНИЯМИ

Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

Аннотация. Нейронная сеть для диагностики обучена на международных данных больных с неврологическими заболеваниями (БН). Нейронная сеть (НС) для поддержки терапии динамически пополняется данными состояния конкретного пациента. Устройство IoT (смартфон) собирает данные пациентов (голос, движение), инициируя их предварительную обработку и извлечение признаков. Эти данные передаются через локальный фреймворк Flask на сервер, использующий Open Semantic Technology for Intelligent Systems (OSTIS) – платформу, которая обрабатывает и интерпретирует информацию о пациентах. Агент прогнозирования на базе НС на сервере, используя обученную нейронную сеть, ставит диагноз пациенту, который передается врачу. Лечение БН требует непрерывной, адаптивной и индивидуальной терапии. Блок электронной терапии на основе нейронной сети, включающий модули пациента и врача, принятия решений и цифрового двойника пациента, расширяет диагностическую систему до поддержки принятия терапевтических решений. Блок выполняет поиск предыдущего состояния пациента; прогностическое моделирование: курс лечения, лекарственную терапию; пояснение для врача. Структура блока включает: рекуррентную нейронную сеть на основе GRU, компонент семантической памяти системы OSTIS, контекстно-зависимые правила в виде SC-графических форм.

Ключевые слова: IoT, нейросетевые модели, граф знаний болезни, электронная диагностики и терапия, цифровой двойник

Введение

Болезнь Паркинсона (БП), прогрессирующее нейродегенеративное заболевание, представляет серьезную проблему для миллионов пациентов и их семей по всему миру. Едва заметные симптомы на ранних стадиях заболевания часто трудно распознать, что приводит к несвоевременной постановке диагноза и упущенным возможностям оптимального лечения [1]. Подтверждение БП преимущественно основывается на оценке истории болезни и клинических проявлений, при этом отсутствуют точные и объективные методы раннего выявления, что ограничивает эффективность лечения заболевания и терапевтических стратегий.

В работе [2] проанализированы четырнадцать признаков движения пациента, которые включают пять вариантов дрожания, шесть вариантов мерцания, два признака гармоничности и среднюю автокорреляцию основного частотного признака. В статье [3] предложен метод, основанный на распознавании и классификации с применением глубокой нейронной сети (DNN) в сочетании с мини-пакетным градиентным спуском (МПГС), для дифференциации пациентов с БП и здоровых людей по признакам изменения голоса.

Появление технологии Интернета вещей (IoT) открыло новые возможности для диагностики и лечения БП. Интеграция датчиков, носимых устройств и интеллектуальных систем анализа, платформы для сбора медицинских данных, разработанной Кимом и соавторами [4], использующий технологию Fast Healthcare Interoperability Resources (FHIR), хранит и передает данные о давлении на стопы пациентов с БП,

демонстрируя эффективность устройств Интернета вещей при непрерывном наблюдении за пациентами. Интеллектуальная система, основанная на голосовых записях и унифицированной шкале оценки болезни Паркинсона (UPDRS), предложенная в статье [5], отличается хранением данных о пациентах и проведением анализа и диагностики в режиме реального времени.

В данной статье рассматривается применение нейронных сетей и технологий IoT для электронной диагностики и поддержки терапии пациентов на базе цифрового двойника. Использование открытой семантической технологии интеллектуальных систем (OSTIS) [6] при разработке прототипа данной ИС ускорило создание сложных графов знания предметной области БП и интеллектуальных механизмов для диагностики и терапии.

Структура и функционирование подсистемы диагностики

Для реализации авторской модели распознавания БП [7] была разработана подсистема ИТ-диагностики с использованием технологии НС, представленная на рисунке 1.

На клиентском уровне мобильные платформы, работающие на базе Android, iOS, служат пользовательскими интерфейсами для пациентов и врачей, позволяя вводить исходные медицинские данные и получать результаты. Смартфоны, сконфигурированные для сбора голосовых данных пациентов, используют микрофон и приложения для записи и передачи этих данных на локальную серверную инфраструктуру. Данная ин-

фраструктура включает веб-сервер, действующий как шлюз для HTTP-запросов, и интерфейс WSGI, который

соединяет веб-сервер с приложением Flask, обеспечивая беспрепятственный обмен данными [8].




Рисунок 1. Структура подсистемы для диагностики БП

Приложение Flask, являющееся компонентом системного интерфейса OSTIS, предоставляет семантический веб-интерфейс, который переводит сложный семантический код (SC-код) в понятный человеку формат. Управление данными осуществляется в хранилище данных, которое включает базу данных SQL или NoSQL, в зависимости от требований приложения. Диагностирование в системе выполняется агентом прогнозирования, базирующего на нейронных сетях (GRU, LSTM, RNN). Веб-платформа OSTIS поддерживает систему с веб-браузером для доступа пользователей, сетевую инфраструктуру для управления семантической памятью (SC-memory), хранения базы знаний и визуализации SC-кода.

Предварительно через смартфон вводятся голосовые данные пациентов с установленной БП, и осуществляется обучение нейронной сети на их основе [7]. В процессе обучения НС извлекает специфические голосовые признаки, связанные с симптомами БП: дрожание, нестабильность интонации и изменение ритма речи [9]. Работа системы начинается со сбора данных, где смартфон выступает в качестве устройства для ввода голосовых данных диагностируемых на БП пациентов в режиме реального времени. Эти данные проходят предварительную обработку в смартфоне, включающую нормализацию, извлечение признаков, отбор для устранения помех и выделения закономерностей, что позволяет подготовить их к дальнейшему анализу. После предварительной обработки данные архивируются в базе данных. Затем выполняется нейросетевой ана-

лиз на базе обученной сети, являющийся частью модуля обработки знаний платформы OSTIS, при этом данные анализируются агентом прогнозирования. Данная подсистема защищена патентом на изобретение [10].

Результаты прогнозирования доводятся до сведения медицинских работников и пациентов через веб-интерфейс пользователя, разработанный с использованием Flask и позволяющий взаимодействовать через веб-браузеры на клиентских устройствах. Врач оценивает результаты работы системы в контексте общей истории болезни пациента, используя эту информацию для принятия обоснованных решений об уходе за пациентом, включая корректировку лечения и планирование дальнейших обследований.

Сбор и обработка данных с мобильных устройств. Для сбора и обработки голосовых данных пациентов с БП использовалась PyAudio (библиотека Python) для доступа к функциям микрофона смартфона. Были заданы звуковые параметры микрофона с частотой дискретизации 44100 Гц, одним каналом и разрядностью 16 бит для обеспечения высокого качества собираемых голосовых данных. Был создан аудиопоток для приема и записи голосовых данных. Перед началом записи участники проходили инструктаж.

Потом запускалась функция записи, в ходе которой были собраны образцы голоса каждого участника, с трехкратным повторением произношения гласного звука /a/ для согласованности. Собранные голосовые данные сначала проходили стадию предварительной обработки, включающей шумоподавление и норма-

лизацию аудиосигнала, чтобы устранить фоновый шум и другие помехи, обеспечивая точность анализа. Анализ во временной области был применен для извлечения основных характеристик речевого сигнала (форма сигнала, энергия и длительность), в то время как анализ в частотной области был сосредоточен на спектральном распределении, частотных компонентах и связанных с ними характеристиках. Внимание было уделено частотным кепстральным коэффициентам Mel (MFCC) и вейвлет-коэффициентам, которые отражают специфические свойства голосового сигнала и особенно эффективны при выявлении голосовых аномалий у пациентов с БП [7].

Выделенные признаки были нормализованы, чтобы обеспечить сопоставимость между ними и предотвратить непропорциональное влияние одной из них на последующее обучение модели. Предварительно обработанные данные о голосовых функциях были упакованы в формат JSON для безопасной передачи на центральный сервер Flask по протоколу HTTP для дальнейшего анализа [6]. Данные отправлены на сервер Flask с помощью POST-запроса. После приема сервер Flask, основываясь на типе данных и определенных процедурах обработки, выполнил соответствующие задачи анализа данных и обучения модели.

Нейросетевой анализ и интеграция знаний OSTIS. После сохранения результатов прогнозирования в базе данных OSTIS framework они становятся доступными в хранилище знаний системы. Сервер

OSTIS оснащен семантическим веб-интерфейсом, обеспечивающим прямое взаимодействие пользователя с интеллектуальной системой. На рисунке 2 показаны SCn-узлы в базе знаний веб-интерфейса OSTIS.

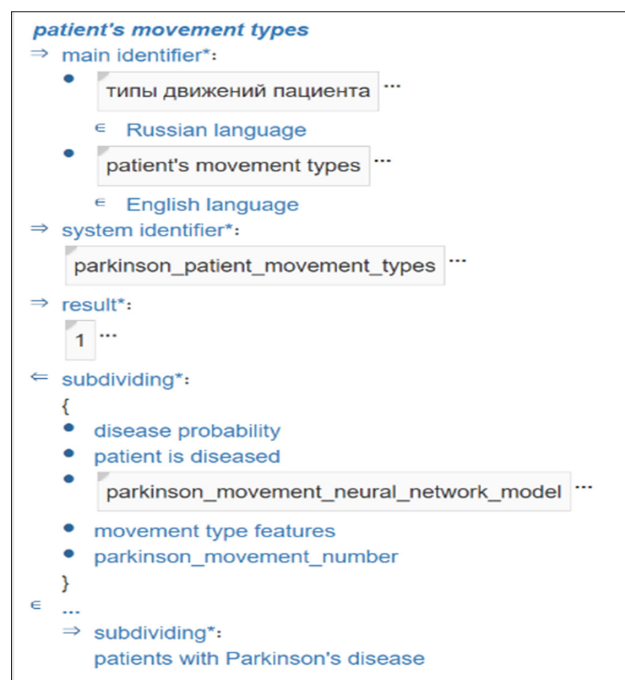


Рисунок 2. Узлы, представленные в базе знаний веб-интерфейса OSTIS




Рисунок 3. SCg-узлы, представленные в базе знаний веб-интерфейса OSTIS

Основываясь на характеристиках результатов прогнозирования, платформа OSTIS предлагает множество инструментов для визуализации и анализа данных [4]. Это позволяет пользователям вникать в данные, создавать аналитические отчеты или проводить дополнительные исследования. На рисунке 3 показаны

SCg-узлы в хранилище знаний OSTIS.

Модуль терапии БП с цифровым двойником

Долгосрочное лечение болезни Паркинсона требует непрерывной, адаптивной и индивидуальной те-

рации. Для решения этой проблемы разработан блок электронной терапии (модули пациента и врача, принятие решений, цифровой двойник на НС), который дополняет диагностическую систему динамической поддержкой терапевтических решений (рисунок 4). Это дополнение использует временные данные о ходе болезни пациента, прогностическое моделирование результатов лечения и предложения индивидуальных вмешательств для клинической поддержки. Цифровой двойник (Twin) – это динамическое цифровое представление пациента с диагностированной БП и риском ее развития. В отличие от статичных моделей, цифровой двойник сохраняет в памяти информацию о состоянии пациента с течением времени, которая постоянно обновляется благодаря взаимодействию с носимыми устройствами, вводу данных пользователем и системным прогнозам. Twin объединяет сенсорные данные (речевые паттерны, информацию о походке), клинические данные, историю лечения и результаты нейронного анализа в единый временной профиль. Блок реализован в виде гибридной системы, которая сочетает в себе рекуррентную нейронную сеть на основе GRU

(анализирует временные и последовательные взаимосвязи при прогрессировании симптомов) и компонент семантической памяти системы OSTIS (хранит варианты решений, реакции на лечение и контекстно-зависимые правила).

Эти два компонента соединены через интерфейсный уровень, который позволяет нейронной модели считывать данные из семантического графа знаний и записывать их в него, тем самым постоянно обогащая цифровой двойник как обучением, основанным на данных, так и знаниями, полученными под руководством человека.

На рисунке 4 представлена структура, описывающая поток данных взаимодействия врача с пациентом. Поток записывается в цифровой двойник в режиме реального времени, происходит поиск и обработка временных данных, моделирование прогнозов развития БП, формирование новых данных для лечения с поддержкой врача. Данный модуль (цифровой двойник) работает в трехшаговом режиме, обеспечивая замкнутый цикл обратной связи для интеллектуальной терапевтической поддержки.




Рисунок 4. Блок электронной терапии БП на нейронной сети

1. *Поиск предыдущего состояния и синхронизация данных.* При каждой регистрации в клинике или при получении данных цифровой двойник получает доступ к предыдущим записям пациента из SC-памяти, что включает в себя оценку речи и двигательных функций с отметками времени; предыдущие назначения (лекарства, дозировки, планы физиотерапевтических процедур); прошлые прогнозы модели и одобренные врачом вмешательства. Это представлено в виде

семантического подграфа, позволяющего параллельно выполнять как логические рассуждения, так и нейронный вывод.

2. *Прогностическое моделирование.* Используя последние наблюдения в качестве входных данных, модель, основанная на GRU, моделирует ожидаемую динамику симптомов в течение следующих 1–4 недель; прогнозируемую реакцию пациента на различные сценарии лечения (например, коррекцию медикаментоз-

ного лечения, логопедические занятия); оценку вероятности двигательных или когнитивных нарушений. Структура модели включает механизмы привлечения внимания, позволяющие выделить важные временные эпизоды (резкие изменения симптомов после предшествующей терапии), тем самым улучшая ее прогностические возможности. При каждом запуске моделирования генерируется набор возможных терапевтических стратегий, каждая из которых сопоставляется с вероятностной оценкой (вероятность улучшения симптомов, риск побочных эффектов и т.д.).

3. *Выходные данные и семантическое объяснение.* Лучшие рекомендации по лечению представляются через семантический веб-интерфейс OSTIS с сопроводительными пояснениями: ожидаемая динамика и вероятность улучшения симптомов; какие предыдущие решения повлияли на рекомендации; как модель оценивала потенциальную пользу (например, система может предложить уменьшить дозу агониста дофамина из-за прогнозируемого риска ухудшения речи, ссылаясь как на анализ временных паттернов нейронной модели, так и на семантические данные, указывающие на предшествующие побочные эффекты).

Эти рекомендации не являются самостоятельными предписаниями, а предназначены для оказания помощи врачам в принятии решений. Каждый предлагаемый план можно редактировать, отклонять или подтверждать через веб-интерфейс.

Разработанная система электронной диагностики

и терапии пациентов с БП передана в РНПЦ психического здоровья для адаптации и практического применения.

Заключение

1. В проведенном исследовании на основе разработанной модели распознавания болезни Паркинсона и обученной нейронной сети представлена подсистема электронной диагностики с использованием технологий Интернета вещей, подтвержденная патентом на изобретение. Для представления знаний о БП разработана онтология, использующая возможности системы OSTIS. Интеграция результатов распознавания БП с базой знаний OSTIS не только способствует мобильной диагностике пациентов, но и улучшает процесс принятия решений по индивидуальному уходу за пациентами.

2. Разработан модуль электронной терапии пациентов с БП, основанный на цифровом двойнике, реализованном на нейронной сети, который дополняет диагностическую подсистему подсистемой поддержки терапевтических решений. Этот модуль реализован в виде гибридной структуры, которая включает рекуррентную нейронную сеть на основе GRU (изучает временные и последовательные взаимосвязи при прогрессировании симптомов) и компонент семантической памяти системы OSTIS (хранит пути принятия решений, реакции на лечение и контекстно-зависимые правила в виде SC-графических форм).

ЛИТЕРАТУРА

1. Sveinbjornsdottir, S. The clinical symptoms of Parkinson's disease / Sigurlaug Sveinbjornsdottir // Journal of Neurochemistry. 2016. Vol. 139, № S1. P. 318–324. DOI: 10.1111/jnc.13691.
2. Upadhyay, S. S. Discriminating Parkinson and healthy people using phonation and cepstral features of speech / Savitha S. Upadhyay, A. N. Cheeran // Procedia Computer Science. 2018. Vol. 143. P. 197–202. DOI: 10.1016/j.procs.2018.10.376.
3. Voiceprint recognition of Parkinson patients based on deep learning / Z. Xu, J. Wang, Y. Zhang, X. He // arXiv. 2018. Dec. P. 1–10. DOI: 10.48550/arXiv.1812.06613.
4. Development of Parkinson patient generated data collection platform using FHIR and IoT devices / D. Y. Kim, S. H. Hwang, M. G. Kim [et al.] // Studies in Health Technology and Informatics. 2017. Vol. 245. 141–145.
5. Anter, A. M. E-health Parkinson disease diagnosis in smart home based on hybrid intelligence optimization model / A. M. Anter, Z. Zhang // Proceedings of the International Conference on Advanced Intelligent Systems and Informatics 2019 / ed.: A. Hassanien, K. Shaalan, M. Tolba. Springer, 2020. Vol. 1058 : Advances in Intelligent Systems and Computing. P. 153–162. DOI: 10.1007/978-3-030-31129-2_15.
6. Organization of online learning using the intelligent metasystem of open semantic technology for intelligent systems / A. Kintonova, A. Sabitov, I. Povkhan [et al.] // Eastern-European Journal of Enterprise Technologies. 2023. Vol. 1, № 2 (121). P. 29–40. DOI: 10.15587/1729-4061.2023.272952.
7. Vishniakou, U. A. IT Diagnostics of Parkinson's disease based on the analysis of voice markers and machine learning / U. A. Vishniakou, Y. Xia // Доклады БГУИР. 2023. Т. 21, № 3. С. 102–110. DOI: 10.35596/1729-7648-2023-21-3-102-110.
8. Vishniakou, U. Models and algorithms for the diagnosis of Parkinson's disease and their realization on the Internet of Things network / U. Vishniakou, Y. Xia // Global Journals of Research in Engineering. 2024. Vol. 24 (J1). P. 43–49. DOI: 10.34257/GJREJVOL24IS1PG43.
9. A Comparative analysis of speech signal processing algorithms for Parkinson's disease classification and the use of the tunable Q-factor wavelet transform / C.O. Sakar, G. Serbes, A. Gunduz [et al.] // Applied Soft Computing. 2019. Vol. 74. P. 255–263. DOI: 10.1016/j.asoc.2018.10.022.
10. Патент 048311, G10L 15/01 (2013.01) G10L 25/00 (2006.01) G16Y 40/20 (2020.01). Способ диагностики болезни Паркинсона в сети Интернет вещей, основанный на анализе голосовых маркеров : № а 202392267 : заяв-

лено 21.07.2023 : опубликовано 13.11.2024 / Вишняков В. А., Ся Ивей ; заявитель Белорусский государственный университет информатики и радиоэлектроники. 12 с. URL: https://libeldoc.bsuir.by/bitstream/123456789/59103/1/Pat_048311.pdf (дата обращения: 17.06.2026).

REFERENCES

1. Sveinbjornsdottir S. The clinical symptoms of Parkinson's disease. *Journal of Neurochemistry*. 2016;139Suppl1:318–324. <https://doi.org/10.1111/jnc.13691>.
2. Upadhy S.S., Cheeran A.N. Discriminating Parkinson and healthy people using phonation and cepstral features of speech. *Procedia Computer Science*. 2018;143:197–202. <https://doi.org/10.1016/j.procs.2018.10.376>.
3. Xu Z., Wang J., Zhang Y., He X. Voiceprint recognition of Parkinson patients based on deep learning. *arXiv*. 2018;Dec:1–10. <https://doi.org/10.48550/arXiv.1812.06613>.
4. Kim D.Y., Hwang S.H., Kim M.G., Song J.H., Lee S.W., and Kim I.K. Development of Parkinson patient generated data collection platform using FHIR and IoT devices. *Studies in Health Technology and Informatics*. 2017;245:141–145.
5. Anter A.M., Zhang Z. E-health Parkinson disease diagnosis in smart home based on hybrid intelligence optimization model. In: Hassanien A, Shaalan K, Tolba M, eds. *Proceedings of the International Conference on Advanced Intelligent Systems and Informatics 2019*. Vol 1058. Advances in Intelligent Systems and Computing. Springer; 2020:153–162. https://doi.org/10.1007/978-3-030-31129-2_15.
6. Kintonova A., Sabitov A., Povkhan I., Khaimulina D., and Gabdreshov G. Organization of online learning using the intelligent metasystem of open semantic technology for intelligent systems. *Eastern-European Journal of Enterprise Technologies*. 2023;1(2(121)):29–40. <https://doi.org/10.15587/1729-4061.2023.272952>.
7. Vishniakou U.A., Xia Y. IT diagnostics of Parkinson's disease based on the analysis of voice markers and machine learning. *Doklady BGUIR [BSUIR Reports]*. 2023;21(3):102–110. <http://dx.doi.org/10.35596/1729-7648-2023-21-3-102-110>.
8. Vishniakou U., Xia Y. Models and algorithms for the diagnosis of Parkinson's disease and their realization on the Internet of Things network. *Global Journals of Research in Engineering*. 2024;24(J1):43–49. <https://doi.org/10.34257/GJREJVOL24IS1PG43>.
9. Sakar C.O., Serbes G., Gunduz A., Tunc H.C., Nizam H., Sakar B.E., and et al. A comparative analysis of speech signal processing algorithms for Parkinson's disease classification and the use of the tunable Q-factor wavelet transform. *Applied Soft Computing*. 2019;74:255–263. <https://doi.org/10.1016/j.asoc.2018.10.022>.
10. Vishniakou U.A., Xia Y. inventors; Belarusian State University of Informatics and Radioelectronics, assignee. Patent 048311, G10L 15/01 (2013.01) G10L 25/00 (2006.01) G16Y 40/20 (2020.01). Sposob diagnostiki bolezni Parkinsona v seti internet veshchei, osnovannyi na analize golosovykh markerov [Method for diagnosing Parkinson's disease in the Internet of Things network based on the analysis of voice markers] : Eurasian patent application EA 202392267 A1. November 13, 2024. Available at: https://libeldoc.bsuir.by/bitstream/123456789/59103/1/Pat_048311.pdf (accessed 17th June 2026) (in Russian).

U. A. VISHNIAKOU

MOBILE SYSTEM WITH A DIGITAL TWIN FOR THE DIAGNOSIS AND SUPPORT OF THERAPY OF PATIENTS WITH NEUROLOGICAL DISEASES

*Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus*

Abstract. The neural network for diagnosis is trained on international data from patients with neurological diseases (ND). The neural network (NN) is dynamically updated with data on the condition of a particular patient to support therapy. An IoT device (smartphone) collects patient data (voice, movement), initiating their preprocessing and feature extraction. This data is transmitted via the local Flask framework to a server using Open Semantic Technology for Intelligent Systems (OSTIS), a platform that processes and interprets patient information. An NN-based forecasting agent on the server, using a trained neural network, performs the patient's diagnosis, which is transmitted to the doctor. Treatment of ND requires continuous, adaptive and individual therapy. The NN-based electronic therapy unit, which includes modules for patient and doctor, decision-making and the patient's digital twin, expands the diagnostic system to support therapeutic decision-making. The block searches for the patient's previous condition; predictive modeling: course of treatment, drug therapy; explanation for the doctor. The block structure includes: a recurrent neural network based on GRU, a component of the semantic memory of the OSTIS system, context-sensitive rules in the form of SC-graphical forms.

Keywords: IoT, neural network models, graph of disease knowledge, electronic diagnostics and therapy, digital twin

**Вишняков Владимир Анатольевич**

Белорусский государственный университет информатики и радиоэлектроники (БГУИР), г. Минск, Республика Беларусь.

Доктор технических наук, профессор. Профессор кафедры инфокоммуникационных технологий БГУИР. Область научных интересов: информационное управление и безопасность, электронный бизнес, интеллектуальные системы управления, сети IoT, нейронные сети, блокчейн. Член двух докторских Советов по защите диссертаций. Автор более 560 научных работ, в том числе 9 монографий (2 на английском языке), 4 учебных пособий с грифом Министерства образования Республики Беларусь, 1 учебного пособия с грифом УМО, 8-томного учебного комплекса «Информационный менеджмент», 215 научных статей, 21 авторского свидетельства и 3 патентов.

Uladzimir Anatolyevich Vishnyakou

Belarusian State University of Informatics and Radioelectronics (BSUIR), Minsk, Republic of Belarus.

Doctor of Technical Sciences, Professor. Professor at the Department of Infocommunication Technologies, BSUIR. Research interests: information management and security, e-business, intelligent control systems, IoT networks, neural networks, and blockchain. Member of two doctoral Dissertation Defense Councils. Author of over 560 scientific papers, including 9 monographs (2 in English), 5 textbooks, 8-volume educational complex "Information Management", 215 scientific articles, 21 author's certificates, and 3 patents.

E-mail: vish@bsuir.by

E-mail: vish2002@list.ru

**ИНФОРМАЦИОННЫЕ
ТЕХНОЛОГИИ**

**INFORMATION
TECHNOLOGIES**

В. О. ГУЛЯЕВ, О. И. ЗАХАРОВА

ЭВОЛЮЦИЯ АРХИТЕКТУР ТРАНСФОРМЕРОВ: ОТ САМОВНИМАНИЯ К ЭФФЕКТИВНЫМ SPARSE-MODEЛЯМ

Поволжский государственный университет телекоммуникаций и информатики
г. Самара, Российская Федерация

Аннотация. Статья посвящена исследованию новых архитектур искусственных нейронных сетей, направленных на улучшение классических трансформеров путем уменьшения вычислительных затрат и увеличения эффективности. Рассматриваются основные этапы эволюции трансформеров, начиная с введения механизма самовнимания и заканчивая современными sparse-моделями. Особое внимание уделяется методам оптимизации, таким как параметрически эффективный fine-tuning (PEFT), адаптивные слои (adapters), а также использование внешних хранилищ знаний и тет-векторов для расширения долговременной памяти моделей. Статья завершается обсуждением текущих достижений, ограничений и перспективных направлений будущих исследований в данной области.

Ключевые слова: трансформеры, механизм самовнимания, sparse-модели, PEFT, тет-векторы

Введение

Трансформеры стали одной из самых влиятельных архитектур в области искусственного интеллекта, обеспечив значительное повышение точности и скорости обработки последовательных данных. Их успех обусловлен введением механизма самовнимания, который позволяет модели параллельно обрабатывать все элементы последовательности, выявляя важные связи между ними. Несмотря на свои достоинства, классические трансформеры сталкиваются с проблемой высоких вычислительных затрат, особенно при увеличении длины входных данных. Для решения этой проблемы исследователи разработали ряд новых подходов, включая sparse-модели и методы параметрически эффективного дообучения (PEFT).

Согласно данным Serverflow архитектура трансформеров основана на принципе самовнимания, что обеспечивает им преимущество перед предыдущими архитектурами, такими как рекуррентные нейронные сети (RNN). Однако рост числа параметров и вычислительная сложность делают традиционные трансформеры ресурсоемкими. Поэтому возникла необходимость разработки более эффективных архитектур.

Исторический обзор трансформеров

Классические трансформеры, представленные в статье «Attention Is All You Need» в 2017 году, положили начало революции в области обработки естественных языков (NLP). Трансформеры кардинально отличаются от предыдущих поколений нейросетей своей способностью одновременно рассматривать всю последовательность ввода. Благодаря механизму самовнимания каждая позиция входа получает уникальную оценку важности относительно остальных позиций, формируя динамические отношения между элементами данных. Этот подход устраняет проблему долгосрочной зависимости, характерную для RNN, и обеспечивает быстрое параллельное выполнение вычислений.




Рисунок 1. Архитектура Transformer

Механизм самовнимания основывается на трех ключевых компонентах: ключах («keys»), запросах («queries») и значениях («values»). Каждый элемент входящего текста преобразуется в три вектора, которые взаимодействуют друг с другом для формирования взвешенного представления контекста. Таким образом, трансформеры создают мощный инструмент для понимания семантической структуры данных.

Однако классическая архитектура имеет и недостатки. Основной недостаток заключается в экспоненциальном росте вычислительной нагрузки при увеличении размера вводимых данных. Время выполнения операций растет пропорционально квадрату длины последовательности, что создает трудности при применении моделей на длинных документах или временных рядах [1].

Современные подходы к повышению эффективности трансформеров

Учитывая перечисленные выше проблемы классических трансформеров, научное сообщество активно ищет пути повышения эффективности этих моделей. Следующим этапом рассмотрим современные подходы, направленные на снижение вычислительной сложности и улучшение масштабируемости трансформеров, что позволит расширить область их применения и повысить практическую ценность. Чтобы справиться с ограничениями классических трансформеров, исследователями были предложены различные инновационные подходы, направленные на повышение эффективности и снижение вычислительных затрат. Рассмотрим подробнее некоторые из наиболее успешных современных методов.

Sparse-модели

Классические трансформеры сталкиваются с серьезным ограничением: объем используемой памяти растет квадратично с увеличением длины последовательности. Причина – в механизме внимания, который вычисляет веса для всех пар токенов, формируя плотную матрицу. Sparse-модели трансформеров решают эту проблему иначе: они фокусируются только на наиболее значимых взаимодействиях, создавая разреженную матрицу внимания, где явно задано лишь « $n * n$ » элементов.

Благодаря этому модели могут эффективно обрабатывать очень длинные контексты. Яркий пример – генерация изображений, где учитываются сложные корреляции между пикселями. Но есть и обратная сторона: модель не «видит» те связи, которые исключены из разреженной структуры. Впрочем, даже токены без прямой связи способны влиять друг на друга через более глубокие слои – как в сверточных сетях, где рецепторное поле растет с добавлением новых слоев.

Еще одно преимущество подхода – возможность явно заложить в модель предположения о структуре данных (inductive bias). Мы описываем входные данные через сущности (слова, пиксели, узлы графа), а затем, проектируя структуру разреженной матрицы, указываем, какие из них, по нашему мнению, должны взаимодействовать. Остается лишь подобрать подходящую архитектуру и проверить, насколько хорошо модель обучается в таких условиях [2].

Параметрически эффективный fine-tuning (PEFT)

Параметрически эффективный fine-tuning направлен на преодоление ключевого ограничения больших языковых моделей (LLMs) – избыточной ресурсоемкости, обусловленной необходимостью обновления огромного числа параметров.

В традиционных схемах подвергаются все параметры модели (в объеме миллионов или миллиардов), что влечет высокие вычислительные затраты и длительное время обработки. PEFT предлагает принципиально иную стратегию: вместо глобальной перенастройки он предполагает модификацию лишь малой доли параметров базовой модели за счет внедрения специализированных компонентов — так называемых модулей адаптации (adapter modules). Такие модули вносят минимальное число дополнительных параметров и эффективно обучаются даже на ограниченных наборах данных.

Принцип действия PEFT базируется на трех положениях:

1. Базовая LLM сохраняется в неизменном виде.
2. К ней добавляется компактная модульная подсистема (например, adapter layer) с небольшим числом параметров.
3. Адаптация к конкретной задаче затрагивает исключительно эти дополнительные параметры.

Это существенно сокращает время дообучения и снижает нагрузку на вычислительные ресурсы, позволяя крупным моделям быстро адаптироваться к узким задачам без переобучения всей архитектуры.

Среди распространенных реализаций PEFT выделяют:

1. **Adapter Modules** – компактные слои, встраиваемые в каждую позицию трансформера и хранящие минимум параметров для целевой адаптации;
2. **LoRA (Low-Rank Adaptation)** – метод, добавляющий к сети низкоранговые матрицы, которые обучаются исключительно под конкретную задачу;
3. **Prompt Learning** – подход, вовсе не модифицирующий параметры модели, а генерирующий специальные подсказки (prompts) для ввода дополнительной информации при решении задачи [3].

Использование mem-векторов

Модели трансформеров традиционно страдают от недостатка долговременной памяти, так как информация, обработанная на ранних стадиях, теряется в процессе передачи сигнала через слои. Чтобы решить эту проблему, были предложены mem-векторы – специальный вид вспомогательных представлений, предназначенных для накопления и последующего повторного использования важной информации.

Mem-вектор (memory vector) – это дополнительное векторное представление, которое интегрируется в архитектуру трансформера и служит своего

рода «банком памяти». Когда модель проходит этап обучения или обработки данных, она записывает особо ценные фрагменты информации в эти тем-векторы, к которым затем может обратиться позднее при выполнении последующих шагов.

Пример: в диалоговом боте, использующем тем-векторы, каждое сообщение собеседника может ассоциироваться с уникальным тем-вектором, который впоследствии используется для поддержания непрерывности беседы и лучшего понимания контекста.

Преимущества использования тем-векторов

1. Долговременная память: позволяет трансформеру лучше удерживать важную информацию на протяжении долгих периодов времени, улучшая его способность понимать контекст и действовать адекватно ситуации.

2. Расширяемость: модель может поддерживать любое количество тем-векторов, увеличивая общую емкость памяти без изменения базовой архитектуры.

3. Повышенная точность: поскольку тем-векторы сохраняют ключевые моменты контекста, модель принимает более обоснованные решения при классификации, генерации текста или других задачах [4].

Практические приложения и результаты

Эффективность и производительность современных архитектур трансформеров позволили достичь значительных успехов в различных областях. Они обеспечивают высокую точность и гибкость, одновременно уменьшая потребности в ресурсах и энергии, что делает их доступными даже для небольших устройств.

Методики параметрического эффективного дообучения (например, LoRA) упростили процесс обновления больших языковых моделей, сделав его быстрее и дешевле. Добавление минимальных дополнительных параметров снижает затраты на обучение, сохраняя качество результата.

Разработка тем-векторов позволила расширить память трансформеров, эффективно сохраняя важную информацию для решения сложных задач. Такие подходы помогают справляться с большими объемами данных и обеспечивать высокое качество работы.

Примером успешного внедрения трансформеров в медицинскую сферу стала система AlphaFold, разработанная DeepMind. Она обеспечивает точное прогно-

зирование структуры белков, что способствует ускоренному поиску новых лекарственных препаратов.

Образование также выигрывает от применения трансформеров. Автоматизированные системы оценки успеваемости и персонализации учебных планов способствуют улучшению качества образования, помогая учителям эффективнее организовывать учебный процесс.

Наконец, креативные индустрии получили мощный импульс благодаря новым алгоритмам на основе трансформеров. Искусственный интеллект способен создавать уникальные художественные произведения, тексты и музыкальное содержание, стимулируя развитие творческого потенциала [5–7].

Заключение

Исследование показало, что эволюция архитектур трансформеров прошла путь от простых механизмов самовнимания до сложных sparse-моделей, оптимизированных для снижения вычислительных затрат и повышения эффективности.

Основные выводы исследования

1. Развитие sparse-моделей. Современные sparse-модели позволяют обрабатывать длинные последовательности данных с минимальными ресурсами, обеспечивая высокую производительность и энергоэффективность.

2. Эффективность fine-tuning. Параметрически эффективные методы дообучения (PEFT) позволили снизить затраты на обучение и сделать крупные языковые модели (LLMs) доступными для широкого круга пользователей.

3. Расширение возможностей памяти. Использование тем-векторов и внешних хранилищ знаний позволило трансформерам сохранять и повторно использовать важную информацию, улучшив их способность понимать контекст и решать комплексные задачи.

Эти достижения расширяют область применения трансформеров, делая их полезными инструментами в медицине, биологии, образовании и искусстве. Дальнейшие исследования будут направлены на совершенствование методов оптимизации, расширение функциональных возможностей и создание более универсальных моделей, способных справляться с разнообразными задачами.

ЛИТЕРАТУРА / REFERENCES

1. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., et al. Attention is all you need. arXiv [Preprint]. 2017. Available from: <https://arxiv.org/abs/1706.03762> (accessed 12 Jun 2026).
2. Child R., Gray S., Radford A., Sutskever I. Generating long sequences with sparse transformers. arXiv [Preprint]. 2019. Available from: <https://arxiv.org/abs/1904.10509> (accessed 12 Jun 2026).
3. Hu E.J., Shen Y., Wallis P., Allen-Zhu Z., Li Y., Wang S., et al. LoRA: Low-rank adaptation of large language models. arXiv [Preprint]. 2021. Available from: <https://arxiv.org/abs/2106.09685> (accessed 12 Jun 2026).
4. Bulatov A., Kuratov Y., Burtsev M.S. Recurrent memory transformer. arXiv [Preprint]. 2022. Available from: <https://arxiv.org/abs/2207.06881> (accessed 12 Jun 2026).

5. Ramesh A., Pavlov M., Goh G., Scott G., Voss C., Radford A., et al. Zero-shot text-to-image generation. arXiv [Preprint]. 2021. Available from: <https://arxiv.org/abs/2102.12092> (accessed 12 Jun 2026).
6. Dhariwal P., Jun H., Payne C., Kim J.W., Radford A., Sutskever I. Jukebox: A Generative model for music. arXiv [Preprint]. 2020. Available from: <https://arxiv.org/abs/2005.00341> (accessed 12 Jun 2026).
7. Brown T.B., Mann B., Ryder N., Subbiah M., Kaplan J., Dhariwal P., et al. Language models are few-shot learners. arXiv [Preprint]. 2020. Available from: <https://arxiv.org/abs/2005.14165> (accessed 12 Jun 2026).

V. O. GULYAEV, O. I. ZAKHAROVA

EVOLUTION OF TRANSFORMER ARCHITECTURES: FROM SELF-ATTENTION TO EFFICIENT SPARSE MODELS

*Volga State University of Telecommunications and Informatics
Samara, Russian Federation*

Abstract. The article is devoted to the study of new architectures of artificial neural networks aimed at improving classical transformers by reducing computational costs and increasing efficiency. The main stages of the evolution of transformers are considered, starting with the introduction of the mechanism of self-attention and ending with modern sparse models. Particular attention is paid to optimization techniques such as parametrically efficient fine-tuning (PEFT), adaptive layers (adapters), as well as the use of external knowledge repositories and memory vectors to expand the long-term memory of models. The article concludes with a discussion of current achievements, limitations, and promising areas for future research in this area.

Keywords: transformers, self-attention mechanism, sparse models, PEFT, memory vectors

Гуляев Владислав Олегович

Поволжский государственный университет телекоммуникаций и информатики, г. Самара, Российская Федерация. Магистрант.

Vladislav O. Gulyaev

Volga State University of Telecommunications and Informatics, Samara, Russian Federation. Master's student.

E-mail: vladislavgulyaev03@gmail.com

Захарова Оксана Игоревна

Поволжский государственный университет телекоммуникаций и информатики, г. Самара, Российская Федерация. Заместитель заведующего Научно-исследовательской лабораторией искусственного интеллекта.

Oksana I. Zakharova

Volga State University of Telecommunications and Informatics, Samara, Russian Federation. Deputy Head of the Research Laboratory of Artificial Intelligence.

E-mail: o.zakharova@psuti.ru

О ЖУРНАЛЕ

Международный научно-технический журнал «Системный анализ и прикладная информатика»
издается 4 раза в год, на русском и английском языках. Распространяется на территории
Беларуси, России и в странах СНГ. В журнале публикуются статьи по системному анализу,
программному обеспечению информационных технологий, хранению и обработке данных,
защите информации, применению информационных технологий в образовательном процессе.

Журнал «Системный анализ и прикладная информатика» является отличной площадкой для продвижения результатов научных исследований не только известных, но и начинающих исследователей. Журнал включен в крупнейшие базы данных научного цитирования: РИНЦ, ЭБС «Лань», Google Scholar, Cyberleninka, EBSCO, ROAR, BASE Search, OpenAIRE, WorldCat, DOAJ, которые признаны авторитетными для мирового научного сообщества.

Подписаться на журнал можно через подписные каталоги:
 РУП «Белпочта», ООО «Прессинформ», ООО «Криэйтив Сервис Бэнд»,
 ООО «Екатеринбург-Опт», ООО «Глобалпресс»

Подписной индекс журнала «Системный анализ и прикладная информатика»:
Ведомственный - 013902 Индивидуальный - 01390

Также предлагаем услуги по размещению рекламы в журнале
«Системный анализ и прикладная информатика»

Вид рекламного модуля	Для Республики Беларусь (стоимость в бел. руб. с НДС)	Для стран СНГ (стоимость в рос. руб.)
На обложке (стр. 2, 3) полноцветный	689,88	26975
Внутри журнала (формат 1/1), полноцветный	536,49	20950
Внутри журнала (формат 1/2), полноцветный	263,27	11235
Внутри журнала (формат 1/1), черно-белый	363,10	11235
Внутри журнала (формат 1/2), черно-белый	181,56	5390

Размещение рекламы в очередном номере осуществляется
после предварительной оплаты Заказчиком
Информацию для рекламодателей можно получить по тел. +375 44 566 47 88
e-mail: l.katkova@bntu.by

Адрес и телефоны редакции:
Республика Беларусь, г. Минск, 220013, пр. Независимости, 65
тел. +375 17 266 26 58
www.sapi.bntu.by
e-mail: ca_pi@bntu.by