

ISSN 2518-1092

НАУЧНЫЙ РЕЗУЛЬТАТ

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

RESEARCH RESULT. INFORMATION TECHNOLOGY

11(1) 2026

16+

Сайт журнала:
rinformation.ru
сетевой научный рецензируемый журнал
online scholarly peer-reviewed journal



Журнал зарегистрирован в Федеральной службе по надзору в сфере связи, информационных технологий и массовых коммуникаций (Роскомнадзор)
Свидетельство о регистрации средства массовой информации Эл. № ФС77-69101 от 14 марта 2017 г.
Журнал включен в Перечень ВАК рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание ученых степеней кандидата и доктора наук (1.2.1. Искусственный интеллект и машинное обучение, 2.3.1. Системный анализ, управление и обработка информации, статистика).
Журнал зарегистрирован в Российском индексе научного цитирования (РИНЦ).
The journal has been registered at the Federal service for supervision of communications information technology and mass media (Roskomnadzor)
Mass media registration certificate El. № FS 77-69101 of March 14, 2017
The journal is included into the List of Higher Attestation Commission of peer-reviewed scientific publications where the main scientific results of dissertations for obtaining scientific degrees of a candidate and doctor of science should be
(1.2.1. Artificial Intelligence and machine learning, 2.3.1. The system analysis, management and information processing, statistics).
The journal is introduced in Russian Science Citation Index (RSCI).



Том 11, № 2. 2026

СЕТЕВОЙ НАУЧНО-ПРАКТИЧЕСКИЙ ЖУРНАЛ

Издается с 2016 г.

ISSN 2518-1092



Volume 11, № 2. 2026

ONLINE SCHOLARLY PEER-REVIEWED JOURNAL

First published online: 2016

ISSN 2518-1092

РЕДАКЦИОННАЯ КОЛЛЕГИЯ:

ГЛАВНЫЙ РЕДАКТОР: **Жихарев А.Г.**, доктор технических наук, доцент, профессор кафедры информационно-телекоммуникационных систем и технологий Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

ЗАМЕСТИТЕЛЬ ГЛАВНОГО РЕДАКТОРА: **Черноморец А.А.**, доктор технических наук, доцент, профессор кафедры прикладной информатики и информационных технологий Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

ОТВЕТСТВЕННЫЙ СЕКРЕТАРЬ: **Болгова Е.В.**, кандидат технических наук, доцент, доцент кафедры прикладной информатики и информационных технологий Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

РЕДАКТОР АНГЛИЙСКИХ ТЕКСТОВ: **Ляшенко И.В.**, кандидат филологических наук, доцент, доцент кафедры английской филологии и межкультурной коммуникации Белгородского государственного национального исследовательского университета (г. Белгород, Россия).

ЧЛЕНЫ РЕДАКЦИОННОЙ КОЛЛЕГИИ:

Басов О.О., доктор технических наук, доцент, исполнительный директор (Общество с ограниченной ответственностью «СПИЧАП», г. Санкт-Петербург, Россия).

Белов С.П., доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Волчков В.П., доктор технических наук, профессор (Московский технический университет связи и информатики, г. Москва, Россия).

Иващук О.А., доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Калмыков И.А., доктор технических наук, профессор (Северо-Кавказский федеральный университет, г. Ставрополь, Россия).

Корсунов Н.И., заслуженный деятель науки РФ, доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Коськин А.В., доктор технических наук, профессор (Орловский государственный университет им. И.С. Тургенева, г. Орел, Россия).

Ломазов В.А., доктор физико-математических наук, профессор (Белгородский государственный аграрный университет им. В.Я. Горина, г. Белгород, Россия).

Маторин С.И., доктор технических наук, профессор (Белгородский государственный национальный исследовательский университет, г. Белгород, Россия).

Наджаджра М.Х., кандидат технических наук, профессор кафедры информационных систем управления (Университет Аль-Истикляль, г. Иерихон, Палестина).

Орлова Ю.А., доктор технических наук, доцент (Волгоградский государственный технический университет, г. Волгоград, Россия).

Таранчук В.Б., доктор физико-математических наук, профессор, (Белорусский государственный университет, г. Минск, Республика Беларусь).

EDITORIAL TEAM:

EDITOR-IN-CHIEF: **Alexander G. Zhikharev**, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Information and Telecommunication Systems and Technologies, Belgorod State National Research University (Belgorod, Russia).

DEPUTY EDITOR-IN-CHIEF: **Andrey A. Chernomorets**, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Applied Informatics and Information Technology, Belgorod State National Research University (Belgorod, Russia).

EXECUTIVE SECRETARY: **Evgeniya V. Bolgova**, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Applied Informatics and Information Technology, Belgorod State National Research University (Belgorod, Russia).

ENGLISH TEXT EDITOR: **Igor V. Lyashenko**, Candidate of Philological Sciences, Associate Professor, Associate Professor of the Department of English Philology and Intercultural Communication, Belgorod State National Research University (Belgorod, Russia).

EDITORIAL BOARD:

Oleg O. Basov, Doctor of Technical Sciences, Associate Professor (Limited Liability Company «SPEECHUP», Saint Petersburg, Russia).

Sergey P. Belov, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Valery P. Volchikov, Doctor of Technical Sciences, Professor (Moscow Technical University of Communications and Informatics, Moscow, Russia).

Olga A. Ivaschuk, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Igor A. Kalmykov, Doctor of Technical Sciences, Professor (North Caucasus Federal University, Stavropol, Russia).

Nikolay I. Korsunov, Honoured Science Worker of Russian Federation, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Alexander V. Koskin, Doctor of Technical Sciences, Professor (Orel State University named after I.S. Turgenev, Orel, Russia).

Vadim A. Lomazov, Doctor of Physical and Mathematical Sciences, Professor (Gorin Belgorod State Agrarian University, Belgorod, Russia).

Sergey I. Matorin, Doctor of Technical Sciences, Professor (Belgorod State National Research University, Belgorod, Russia).

Mohammed H. Najajra, Candidate of Technical Sciences (Al Istiqlal University, Jericho, Palestine).

Yulia A. Orlova, Doctor of Technical Science, Associate Professor (Volgograd State Technical University, Volgograd, Russia).

Valery B. Taranchuk, Doctor of Physical and Mathematical Sciences, Professor (Belarusian State University, Minsk, Belarus).

ИНФОРМАЦИОННЫЕ СИСТЕМЫ
И ТЕХНОЛОГИИINFORMATION SYSTEM
AND TECHNOLOGIES

Кривчикова А.С., Болгова Е.В., Черноморец А.А., Ядута А.З. Метод стеганографического скрывания информации в детализированных областях изображений на основе псевдослучайного встраивания	4	Krivchikova A.S., Bolgova E.V., Chernomorets A.A., Yaduta A.Z. A Method of Information Steganographic Hiding in the Image Detailed Areas Based on Pseudorandom Embedding	4
Федоров М.В., Королев В.А. Сравнительный анализ различных методов математического моделирования политической динамики на основе теории многопоточности	14	Fedorov M.V., Korolev V.A. Comparative Analysis of Different Methods of Mathematical Modeling of Political Dynamics Based on the Multiple Streams Framework	14
Левина Т.М., Альмухаметова Э.И., Чудаков Н.М. Линейная и полиномиальная регрессия как инструменты анализа исторических данных в задачах нефтепереработки	26	Levina T.M., Almukhametova E.I., Chudakov N.M. Linear and Polynomial Regression as Tools for Historical Data Analysis in Oil Refining Problems	26
Хлопов А.М., Сулханов И.И. Системный анализ архитектур и модель выбора для распределённых систем синхронной доставки потокового мультимедийного контента с координацией управляющих сигналов	36	Khlopov A.M., Sulkhanov I.I. Systemic Analysis of Architectures and a Selection Model for Distributed Systems of Synchronous Streaming Multimedia Content Delivery with Control Signal Coordination	36
Кравцов Г.Г. Адаптивная мульти-интервальная шкала (AMIS): алгоритм нормализации агрегированных данных в едином измерительном пространстве	50	Kravtsov G.G. Adaptive Multi-Interval Scale (AMIS): a Normalization Algorithm for Aggregated Data in a Unified Metric Space	50

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ
И ПРИНЯТИЕ РЕШЕНИЙARTIFICIAL INTELLIGENCE
AND DECISION MAKING

Чмыхало Д.С., Газизов А.Р., Легонько О.Л. Система поддержки принятия решений при реагировании на угрозы информационной безопасности	62	Chmykhalo D.S., Gazizov A.R., Legonko O.L. Decision Support System for Responding to Information Security Threats	62
Басов О.О., Колесникова А.И. Подходы к выявлению аномального поведения людей на основе изображений с камер видеонаблюдения	77	Basov O.O., Kolesnikova A.I. Approaches to Detecting Anomalous Human Behavior Based on Images from CCTV Cameras	77
Чигарев Б.Н. Картирование научного ландшафта: библиометрический анализ исследований ИИ и перспективных технологий на базе ArXiv	91	Chigarev B.N. Mapping the Scholarly Landscape: A Bibliometric Analysis of AI and Emerging Technologies on ArXiv	91
Зарипов Е.А., Лазаренко С.А. Оптимизация гиперпараметров моделей машинного обучения на основе эволюционных алгоритмов и суррогатного моделирования	109	Zaripov E.A., Lazarenko S.A. Optimization of Hyperparameters of Machine Learning Models Based on Evolutionary Algorithms and Surrogate Modeling	109

КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ**COMPUTER SIMULATION**

Воскобойников И.С., Гвоздевский И.Н., Булгаков В.Д. Метод адаптивного формирования блоков и индексации неструктурированных данных в децентрализованных системах хранения	121	Voskoboinikov I.S., Gvozdevsky I.N., Bulgakov V.D. Method of Adaptive Block Formation and Indexing of Unstructured Data in Decentralized Storage Systems	121
Горелов С.А., Клёсов Д.Н., Белецкая А.А., Афонин А.Н., Ядута А.З. Классификационная модель и интерактивная виртуальная среда для сценарного анализа технологических процессов животноводства	135	Gorelov S.A., Klyosov D.N., Beletskaya A.A., Afonin A.N., Yaduta A.Z. Classification Model and Interactive Virtual Environment for Scenario Analysis of Technological Process in Livestock Production	135

ИНФОРМАЦИОННЫЕ СИСТЕМЫ И ТЕХНОЛОГИИ INFORMATION SYSTEM AND TECHNOLOGIES

УДК 004.932.2

DOI: 10.18413/2518-1092-2026-11-2-0-1

**Кривчикова А.С.¹
Болгова Е.В.²
Черноморец А.А.²
Ядута А.З.²**

МЕТОД СТЕГАНОГРАФИЧЕСКОГО СКРЫТИЯ ИНФОРМАЦИИ В ДЕТАЛИЗИРОВАННЫХ ОБЛАСТЯХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ПСЕВДОСЛУЧАЙНОГО ВСТРАИВАНИЯ

- ¹⁾ Общество с ограниченной ответственностью "СофТраст",
ул. Королева, 2а, офис 2/207, г. Белгород, 308033, Россия
²⁾ Белгородский государственный национальный исследовательский университет,
ул. Победы, 85, г. Белгород, 308015, Россия

e-mail: 1855159@bsuedu.ru, bolgova_e@bsuedu.ru, chernomorets@bsuedu.ru

Аннотация

Данная статья посвящена разработке метода стеганографического скрывания информации в детализированных областях изображений на основе псевдослучайного встраивания. Детализированные области изображений характеризуются значительным количеством мелких объектов. Информация, скрытно внедренная в такие области, является менее визуально заметной. Для поиска детализированных областей на полутоновом изображении в работе предложен алгоритм на основе пороговой обработки значений градиента, вычисленных с помощью оператора Собеля. Для внедрения информации в битовом виде в выбранные детализированные области исходного изображения в работе применен метод псевдослучайного встраивания. Для внедрения данных в цветные изображения разработанный метод применяется к выбранным цветовым компонентам. Для проверки работоспособности разработанного метода были проведены вычислительные эксперименты. Полученные изображения-контейнеры, содержащие данные, которые были внедрены на основании разработанного метода, визуально практически не отличались от исходных изображений. Извлеченные из изображений-контейнеров данные совпали с внедряемыми данными. Проведенные вычислительные эксперименты продемонстрировали высокую степень скрытности внедрения данных на основании разработанного метода, а также проиллюстрировали, что разработанный метод имеет преимущество в скрытности внедрения данных в выбранные исходные изображения по сравнению с анализируемыми известными методами.

Ключевые слова: стеганографическое скрывание; цифровые изображения; детализированные области; градиент; псевдослучайное встраивание; скрытность внедрения

Для цитирования: Кривчикова А.С., Болгова Е.В., Черноморец А.А., Ядута А.З. Метод стеганографического скрывания информации в детализированных областях изображений на основе псевдослучайного встраивания // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 4-13. DOI: 10.18413/2518-1092-2026-11-2-0-1

**Krivchikova A.S.¹
Bolgova E.V.²
Chernomorets A.A.²
Yaduta A.Z.²**

A METHOD OF INFORMATION STEGANOGRAPHIC HIDING IN THE IMAGE DETAILED AREAS BASED ON PSEUDORANDOM EMBEDDING

- ¹⁾ SofTrust Ltd, 2a Koroleva St., Office 2/207, Belgorod, 308033, Russia

- ²⁾ Belgorod State National Research University,
85 Pobedy St., Belgorod, 308015, Russia

e-mail: 1855159@bsuedu.ru, bolgova_e@bsuedu.ru, chernomorets@bsuedu.ru

Abstract

This article is devoted to the development of a method of the information steganographic hiding in the image detailed areas based on pseudorandom embedding. Detailed image areas are characterized by a significant number of small objects. Hiddenly embedded information in such areas is less visually noticeable. To search the detailed areas in a grayscale image, an algorithm based on threshold processing of gradient values calculated using the Sobel operator is proposed. The pseudorandom embedding method is used to embed information in bit form into selected detailed areas of the source image. To embed data in color images, the developed method is applied to selected color components. Computational experiments were conducted to verify the operability of the developed method. The resulting container images containing the data, which were embedded based on the developed method, visually practically did not differ from the original images. The data extracted from the container images matched the embedded data. The performed computational experiments demonstrated a high degree of secrecy of data embedding based on the developed method, and also illustrated that the developed method has an advantage in the secrecy of data embedding in selected source images compared to the analyzed known methods.

Keywords: steganographic hiding; digital images; detailed areas; gradient; pseudorandom embedding; embedding stealth

For citation: Krivchikova A.S., Bolgova E.V., Chernomorets A.A., Yaduta A.Z. A Method of Information Steganographic Hiding in the Image Detailed Areas Based on Pseudorandom Embedding // Research result. Information technologies. – T.11, № 2, 2026. – P. 4-13. DOI: 10.18413/2518-1092-2026-11-2-0-1

ВВЕДЕНИЕ

Одним из развивающихся в настоящее время направлений компьютерной обработки цифровых изображений является стеганографическое скрытие информации в изображениях с целью ее внедрения в изображения без видимых изменений для человеческого восприятия. Стеганографические методы применяются для защиты авторских прав на мультимедийные данные, для встраивания данных в медицинские снимки, а также в других областях деятельности человека [1-3].

В настоящее время существует значительное количество методов стеганографического скрытия информации в пространственной области цифровых изображениях: метод замены наименее значащего бита (LSB), метод псевдослучайного встраивания, метод замены цветовой палитры и др.. Широко применяется метод LSB, который заключается в замене младших бит двоичного представления значений пикселей изображения на значения бит внедряемой информации и позволяет скрытно внедрить большой объем данных. Метод псевдослучайного встраивания заключается в том, что генерируется псевдослучайная последовательность индексов пикселей, в которые планируется осуществить внедрение, затем в соответствии с данной последовательностью выполняется изменение наименее значащего бита пикселей на основании значений внедряемых бит данных. Известны, также другие методы стеганографического скрытия в пространственной и частотных областях изображения, однако, многие из них не учитывают структуру изображения-контейнера, что может вызывать его значительные искажения в результате внедрения информации [1-8].

Для повышения скрытности внедрения в работе предлагается метод, основанный на внедрении информации в детализированные области изображения на основе псевдослучайного встраивания. Под детализированными областями изображения обычно понимают его фрагменты, обладающих значительным количеством мелких объектов, небольших элементов и деталей других объектов, наличием выраженной текстурированной поверхности. Информация, скрытно внедренная в такие области, является менее визуально заметной, так как искажения, вносимые при встраивании информации, во многих случаях, практически не обнаруживаются на фоне исходной структуры изображения-контейнера. Внедрение данных в детализированные области позволяет снизить визуальные искажения изображения-контейнера [9-11].

В качестве детализированных областей выделяют фрагменты изображений, характеризующиеся наличием следующих элементов:

- текстурированные поверхности: листва деревьев, трава, песок, ткань и т.п.;
- границы объектов, сложные архитектурные элементы и т.п.;
- случайные шумы, определяющие зернистость фотографии, блики, сложные узоры и др.

ВЫДЕЛЕНИЕ ДЕТАЛИЗИРОВАННЫХ ОБЛАСТЕЙ ИЗОБРАЖЕНИЙ

Для поиска детализированных областей на полутоновом изображении в работе предлагается следующий алгоритм на основе вычисления градиента с помощью оператора Собеля (рисунок 1), что позволяет выбрать области изображений со значительным количеством границ на небольшом участке изображения [12, 13].

-1	-2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1

Рис. 1. Маски оператора Собеля:

а – в вертикальном направлении, б – в горизонтальном направлении

Fig. 1. The Sobel operator masks:

a – in the vertical direction, b – in the horizontal direction

1. Вести исходное изображение, размерности $N_1 \times N_2$ пикселей. Если изображение цветное, то преобразовать его в полутоновое изображение. Представить анализируемое изображение в виде матрицы I_0 , размерности $N_1 \times N_2$, значений яркости его пикселей.

2. Создать изображение I , в котором в двоичном представлении значения каждого пикселя изображения I_0 младшему биту присвоено значение 0.

3. Вычислить значения модуля вектора градиента в каждом пикселе изображения I , представить вычисленные значения в виде матрицы G :

3.1. Вычислить оценки частных производных в каждом пикселе изображения I в горизонтальном и вертикальном направлениях с помощью оператора Собеля; представить вычисленные значения оценок частных производных в виде матриц G_x и G_y ;

3.2. Вычислить модуль вектора градиента для каждого элемента матрицы G :

$$G(n_1, n_2) = \sqrt{G_x^2(n_1, n_2) + G_y^2(n_1, n_2)}, \quad n_1 = 1, 2, \dots, N_1, \quad n_2 = 1, 2, \dots, N_2.$$

4. Вычислить m_G среднее значение элементов матрицы G .

5. Разбить матрицу G на блоки $B_{k_1 k_2}$, $k_1 = 1, 2, \dots, K_1$, $k_2 = 1, 2, \dots, K_2$, размерности $M_1 \times M_2$ элементов (предлагаются следующие значения $M_1 = M_2 = 64$).

6. Задать начальное значение счетчика детализированных областей i_B :

$$i_B = 0.$$

7. Выполнить для каждого блока $B_{k_1 k_2}$, $k_1 = 1, 2, \dots, K_1$, $k_2 = 1, 2, \dots, K_2$, матрицы G следующие действия:

7.1. Вычислить $m_{k_1 k_2}$ среднее значение элементов блока $B_{k_1 k_2}$;

7.2. Вычислить $\sigma_{k_1 k_2}^2$ дисперсию элементов блока $B_{k_1 k_2}$;

7.3. Определить значение элементов строки с номером i_B матрицы D координат детализированных областей в зависимости от результатов сравнения полученных значений $m_{k_1 k_2}$ и $\sigma_{k_1 k_2}^2$ с вычисленным на шаге 4 значением m_G и пороговым значением T_σ , например, $T_\sigma = 100$:

если выполняется следующее условие:

$$m_{k_1 k_2} > m_G, \text{ и } \sigma_{k_1 k_2}^2 > T_\sigma,$$

ТО ВЫПОЛНИТЬ:

$$\begin{aligned} i_B &\Leftarrow i_B + 1, \\ D(i_B, 1) &= (k_1 - 1)M_1 + 1, \\ D(i_B, 2) &= (k_2 - 1)M_2 + 1. \end{aligned}$$

8. Конец.

В результате работы данного алгоритма формируется матрица D , размерности $i_B \times 2$, элементы которой содержат координаты детализированных областей исходного изображения I_0 .

СТЕГАНОГРАФИЧЕСКОЕ СКРЫТИЕ ИНФОРМАЦИИ В ДЕТАЛИЗИРОВАННЫХ ОБЛАСТЯХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ПСЕВДОСЛУЧАЙНОГО ВСТРАИВАНИЯ

Для внедрения информации в битовом виде в выбранные детализированные области исходного изображения в работе применяется метод псевдослучайного встраивания [1, 3]. Для этого перед скрытием информации вычисляется псевдослучайная последовательность детализированных областей.

Непосредственно перед внедрением в выбранные детализированные области осуществляется вычисление количества бит V_{data} внедряемых данных и максимального объема V_{max} битовых данных, которые можно скрыть в исходном полутоновом изображении на основании разработанного метода:

$$V_{max} = \frac{M_1}{2} \frac{M_2}{2} i_B.$$

В случае если полученный максимальный объем V_{max} меньше объема V_{data} подготовленных данных для скрытия в изображении, то осуществляется «аварийное» завершение алгоритма.

В противном случае, выполняется преобразование внедряемых данных в бинарный вид, а также формируется псевдослучайная последовательность детализированных областей.

Непосредственно скрытие информации в каждой выбранной детализированной области из псевдослучайной последовательности происходит на основании метода замены наименее значащего бита (метод LSB) при обработке центральных пикселей детализированной области, индексы которых находятся в диапазонах $[M_1/4, 3M_1/4]$ и $[M_2/4, 3M_2/4]$ по каждой из координат соответственно.

Для извлечения информации выполняются действия, аналогичные описанным выше.

Следует отметить, что приведенный метод стеганографического скрытия информации в детализированных областях изображений может быть применен для внедрения в цветные изображения на основании скрытного внедрения в каждую из цветовых компонент изображения.

РЕЗУЛЬТАТЫ ВЫЧИСЛИТЕЛЬНЫХ ЭКСПЕРИМЕНТОВ

Программная реализация разработанного метода стеганографического скрытия информации в детализированных областях изображений на основе псевдослучайного встраивания выполнена средствами языка Python [14, 15]. Основные окна графического пользовательского интерфейса разработанной программной реализации приведены на рисунке 2.




Рис. 2. Основные окна графического пользовательского интерфейса разработанной программной реализации: а – окно скрытного внедрения текста, б – окно отображения полученных результатов

Fig. 2. The graphical user interface main windows of the developed software implementation:
a – a window for text hidden embedding, b – a window for the results displaying

Для проверки работоспособности разработанного метода стеганографического скрытия информации в детализированных областях изображений на основе псевдослучайного встраивания, а также сравнительного оценивания результатов внедрения, полученных на основании разработанного метода и известных методов: метод LSB, метод псевдослучайного встраивания и метод замены цветовой палитры, были проведены вычислительные эксперименты.

Для оценивания искажения изображения-контейнера K , содержащего внедренные данные, относительно исходного изображения I , размерности $N_1 \times N_2$ пикселей, вычислены следующие показатели [16, 17]:

- пиковое отношение сигнала к шуму (PSNR):

$$PSNR = 10 \log_{10} (L^2 / MSE),$$

где L – наибольшее значение пикселей, $L=255$,

MSE – среднеквадратичная ошибка:

$$MSE = \frac{1}{N_1 N_2} \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} (I(i, j) - K(i, j))^2,$$

- индекс структурного сходства (SSIM), позволяющий учитывать структурные изменения информации с точки зрения человеческого восприятия:

$$SSIM = \frac{(2\mu_1\mu_2 + c_1)(2\sigma_{12} + c_2)}{(\mu_1^2 + \mu_2^2 + c_1)(\sigma_1^2 + \sigma_2^2 + c_2)},$$

где μ_1, μ_2 – средние значения яркости пикселей изображений I и K ;

σ_1^2, σ_2^2 – дисперсии значений яркости пикселей изображений I и K ;

σ_{12} – ковариация значений яркости пикселей изображений I и K ;

$$c_1 = (k_1 L)^2, \quad c_2 = (k_2 L)^2, \quad L = 255,$$

$$k_1 = 0,01, \quad k_2 = 0,03.$$

При проведении вычислительных экспериментов скрытное внедрение текстовой информации осуществлено в изображения, полученные из открытых источников интернет. Изображения И1, И2, И3, И4 и И5, в которые осуществлено скрытное внедрение приведены на рисунке 3.



Рис. 3. Исходные изображения
Fig. 3. Source images

Размерности изображений, приведенных на рисунке 3, имеют значения 500×375 , 850×567 , 476×260 , 396×259 и 400×288 пикселей соответственно.

При проведении вычислительных экспериментов на основании разработанного метода размер выделяемых детализированных областей выбран равным 64×64 пикселя, пороговое значение T_σ выбрано равным 100.

Для внедрения была подготовлена текстовая информация, объем которой в битовом представлении равен 27520 бит.

Для внедрения указанного объема данных на основании разработанного метода на исходных изображениях было выделено 9 детализированных областей.

Результаты выделения детализированных областей на основании разработанного метода на исходных изображениях (рисунок 3) приведены на рисунке 4.




Рис. 4. Детализированные области, выделенные на основании разработанного метода
Fig. 4. Detailed areas selected based on the developed method

При проведении вычислительных экспериментов на основании разработанного метода скрытое внедрение данных, объемом 27520 бит, было осуществлено в выделенные детализированные области, приведенные на рисунке 4.

Отметим, что полученные изображения-контейнеры, содержащие данные, которые были внедрены на основании разработанного метода стеганографического скрытия информации в детализированных областях изображений на основе псевдослучайного встраивания, визуально

практически не отличались от исходных изображений. Извлеченные данные совпали с внедряемыми данными.

При проведении вычислительных экспериментов данные, объемом 27520 бит, также были внедрены в соответствующие исходные изображения на основании следующих известных методов скрытного внедрения: метод LSB, метод псевдослучайного встраивания, метод замены цветовой палитры.

Отметим, что в ходе вычислительных экспериментов при применении анализируемых методов извлеченные данные совпали с внедряемыми данными.

Результаты оценивания искажений изображения-контейнера, содержащего внедренные данные, относительно исходного изображения при скрытном внедрении данных на основании анализируемых методов приведены в таблицах 1 и 2.

Таблица 1

Оценивание искажений изображения-контейнера (пиковое отношение сигнала к шуму *PSNR*)

Table 1

The container image distortion estimation (peak signal-to-noise ratio *PSNR*)

Изображение	Метод LSB	Метод псевдослучайного встраивания	Метод замены цветовой палитры	Разработанный метод
И1	69,28	71,40	24,32	72,37
И2	71,42	72,55	29,98	74,49
И3	67,73	67,86	19,87	69,79
И4	67,00	67,96	21,24	69,03
И5	68,97	69,16	25,79	69,37

Таблица 2

Оценивание искажений изображения-контейнера (индекс структурного сходства *SSIM*)

Table 2

The container image distortion estimation (structural similarity index measure *SSIM*)

Изображение	Метод LSB	Метод псевдослучайного встраивания	Метод замены цветовой палитры	Разработанный метод
И1	0,99992	0,99994	0,84096	0,99996
И2	0,99994	0,99997	0,90924	0,99999
И3	0,9997	0,9996	0,7415	0,9999
И4	0,9998	0,9998	0,7313	0,9999
И5	0,9998	0,9997	0,908	0,9999

Данные, приведенные в таблицах 1 и 2, иллюстрируют, что разработанный метод стеганографического скрытия информации в детализированных областях изображений на основе псевдослучайного встраивания имеет преимущество по скрытности внедрения данных в выбранных исходных изображениях по сравнению с анализируемыми известными методами.

ВЫВОДЫ

Таким образом, в данной статье разработан метод стеганографического скрытия информации в детализированных областях изображений на основе псевдослучайного встраивания. Детализированные области изображений характеризуются значительным количеством мелких объектов, небольших элементов и деталей других объектов, наличием выраженной

текстурированной поверхности. Информация, скрытно внедренная в такие области, является менее визуально заметной на фоне исходной структуры изображения-контейнера, тем самым, внедрение данных в детализированные области позволяет снизить визуальные искажения изображения-контейнера.

Для поиска детализированных областей на полутоновом изображении в работе предложен алгоритм на основе пороговой обработки значений градиента, вычисленных с помощью оператора Собеля.

Для внедрения информации в битовом виде в выбранные детализированные области исходного изображения в работе применен метод псевдослучайного встраивания. Перед скрыванием информации вычисляется псевдослучайная последовательность детализированных областей. Скрытие информации в каждой детализированной области, выбранной из псевдослучайной последовательности, происходит на основании метода замены наименее значащего бита при обработке центральных пикселей детализированной области. Для внедрения данных в цветные изображения разработанный метод применяется к заданным цветовым компонентам.

Для проверки работоспособности разработанного метода были проведены вычислительные эксперименты. Полученные изображения-контейнеры, содержащие данные, которые были внедрены на основании разработанного метода, визуально практически не отличались от исходных изображений. Извлеченные из изображений-контейнеров данные совпали с внедряемыми данными. Для оценивания искажений изображений-контейнеров применены пиковое отношение сигнала к шуму и индекс структурного сходства, значения которых продемонстрировали высокую степень скрытности внедрения данных на основании разработанного метода. Были проведены сравнительные вычислительные эксперименты, которые проиллюстрировали, что разработанный метод имеет преимущество в скрытности внедрения данных в выбранные исходные изображения по сравнению с анализируемыми известными методами.

Список литературы

1. Шелухин О.И., Канаев С.Д. Стеганография. Алгоритмы и программная реализация. – М.: Горячая линия. Телеком, 2024. – 592 с.
2. Грибунин В.Г., Оков И.Н., Туринцев И.В. Цифровая стеганография. – М.: Солон-пресс, 2016. – 262 с.
3. Конахович Г.Ф., Пузыренко А.Ю. Компьютерная стеганография. Теория и практика. – Киев: МК-Пресс, 2006. – 288 с.
4. Жиликов Е.Г., Черноморец А.А., Голощапова В.А. Реализация алгоритма внедрения изображений на основе использования неинформационных частотных интервалов изображения-контейнера // Вопросы радиоэлектроники. – 2011. – 4(1). – С. 96-104.
5. Болгова Е.В., Черноморец А.А. О методе субинтервального скрытного внедрения данных в изображения // Научные ведомости Белгородского государственного университета. Серия: Экономика. Информатика. – 2018. – Т. 45. – № 1. – С. 192-201.
6. Жиликов Е.Г., Черноморец А.А., Болгова Е.В., Голощапова В.А. О субполосном внедрении в цветные изображения // Научные ведомости Белгородского государственного университета. Серия: Экономика. Информатика. – 2015. – № 1(198). С. 158-162.
7. Жиликов Е.Г., Черноморец А.А., Болгова Е.В., Гахова Н.Н. Исследование устойчивости стеганографии в изображениях // Научные ведомости Белгородского государственного университета. Серия: Экономика. Информатика. – 2014. – 1(172). – С. 168-174.
8. Кривчикова А.С., Черноморец А.А. О методах стеганографического скрывания информации в изображениях [Электронный ресурс]. – Электрон. журн. – Международный студенческий научный вестник, 2024. – №6. – URL: <https://eduherald.ru/article/view?id=21658> (дата обращения 14.02.2026).
9. Области визуальной детализации и области визуального покоя [Электронный ресурс]. – URL: <https://render.ru/ru/articles/post/11003> (дата обращения 22.12.2025).
10. Семенищев Е.А., Тазетдинова Д.И., Писарев А.В., Жук С.В., Тарасов Д.А. Разработка и исследование методов выделения высокодетализированных объектов на изображениях // Научно-технический вестник Поволжья. – 2012. – № 6. – С. 374-377.

11. Торопов И.А., Семенищев Е.А., Раевская Л.Н., Толстова И.В. Исследование методов обнаружения объектов с высокой детализацией на изображении сцены // Информационные системы и технологии: управление и безопасность. – 2012. – № 1. – С. 267-273.
12. Гонсалес Р., Вудс Р. Цифровая обработка изображений. Издание 3-е, исправленное и дополненное. – М.: Техносфера, 2012. – 1104 с.
13. Muthukrishnan, R. Алгоритмы выделения контуров для сегментации изображений [Электронный ресурс] / R. Muthukrishnan, M. Radha. – URL: <https://masters.donntu.ru/2014/fknt/metelytsia/library/article11.htm> (дата обращения 22.12.2025).
14. Beazley D.M. Python Essential Reference. 4th Edition. Addison-Wesley Professional, 2009. – 717 с.
15. Фёдоров Д. Ю. Программирование на языке высокого уровня Python. – М.: Издательство Юрайт, 2022. – 210 с.
16. Al-Najar Y.A.Y., Soong D.C. Comparison of Image Quality Assessment: PSNR, HVS, SSIM, UIQI. International Journal of Scientific & Engineering Research. – 2008. – Vol. 3. – Iss. 8.
17. Шубников В.Г., Беляев С.Ю. Подавление шума и оценка различий в изображениях // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика. Телекоммуникации. Управление. – 2013. – № 3(174). – С. 58-66.

References

1. Sheloukhin O.I., Kanaev S.D. Steganography. Algorithms and Software Implementation. – Moscow: Goryachaya Liniya. Telecom, 2024. – 592 p.
2. Gribunin V.G., Okov I.N., Turintsev I.V. Digital Steganography. – Moscow: Solon-Press, 2016. – 262 p.
3. Konakhovich G.F., Puzyrenko A.Yu. Computer Steganography. Theory and Practice. – Kyiv: MK-Press, 2006. – 288 p.
4. Zhilyakov E.G., Chernomorets A.A., Goloshchapova V.A. Computer Implementation of the Image Embedding Algorithm Based on Non-Informative Frequency Intervals of Container Image // Voprosy Radioelektroniki. – 2011. – 4(1). – P. 96-104.
5. Bolgova E.V., Chernomorets A.A. On the method of subinterval data hidden embedding in images // Belgorod State University. Scientific Bulletin. Series: Economics. Information technologies. – 2018. – Vol. 45. – No. 1. – P. 192-201.
6. Zhilyakov E.G., Chernomorets A.A., Bolgova E.V., Goloshchapova V.A. About subband embedding in colored images// Belgorod State University. Scientific Bulletin. Series: Economics. Information technologies. – 2015. – No. 1(198). – P. 158-162.
7. Zhilyakov E.G., Chernomorets A.A., Bolgova E.V., Gakhova N.N. Investigation of the steganography stability in images // Belgorod State University. Scientific Bulletin. Series: Economics. Information technologies. – 2014. – 1(172). – P. 168-174.
8. Krivchikova A.S., Chernomorets A.A. On methods of steganographic concealment of information in images [Electronic resource]. – Electronic journal – International student scientific bulletin, 2024. – No. 6. – URL: <https://eduherald.ru/article/view?id=21658> (date of access 02/14/2026).
9. Areas of visual detail and areas of visual rest [Electronic resource]. – URL: <https://render.ru/ru/articles/post/11003> (date of access 12/22/2025).
10. Semenischev E.A., Tazetdinova D.I., Pisarev A.V., Zhuk S.V., Tarasov D.A. Development and study of methods for identifying highly detailed objects in images // Scientific and Technical Bulletin of the Volga Region. – 2012. – No. 6. – P. 374-377.
11. Toropov I.A., Semenischev E.A., Raevskaya L.N., Tolstova I.V. Study of methods for detecting highly detailed objects in a scene image // Information Systems and Technologies: Management and Security. – 2012. – No. 1. – P. 267-273.
12. Gonzalez R., Woods R. Digital Image Processing. 3rd edition, corrected and supplemented. – Moscow: Tekhnosfera, 2012. – 1104 p.
13. Muthukrishnan, R. Contour Detection Algorithms for Image Segmentation [Electronic resource] / R. Muthukrishnan, M. Radha. – URL: <https://masters.donntu.ru/2014/fknt/metelytsia/library/article11.htm> (date of access 12/22/2025).
14. Beazley D.M. Python Essential Reference. 4th Edition. Addison-Wesley Professional, 2009. – 717 p.
15. Fedorov D. Yu. High-Level Programming in Python. – Moscow: Yurait Publishing House, 2022. – 210 p.
16. Al-Najar Y.A.Y., Soong D.C. Comparison of Image Quality Assessment: PSNR, HVS, SSIM, UIQI. International Journal of Scientific & Engineering Research. – 2008. – Vol. 3. – Iss. 8.

17. Shubnikov V.G., Belyaev S.Yu. Noise Reduction and Difference Assessment in Images // Scientific and Technical Bulletin of St. Petersburg State Polytechnical University. Computer Science. Telecommunications. Management. – 2013. – No. 3(174). – P. 58-66.

Кривчикова Анастасия Сергеевна, старший инженер-программист, Общество с ограниченной ответственностью "СофтТраст", г. Белгород, Россия

Болгова Евгения Витальевна, кандидат технических наук, доцент, доцент кафедры прикладной информатики и информационных технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Черноморец Андрей Алексеевич, доктор технических наук, доцент, профессор кафедры прикладной информатики и информационных технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Ядута Анна Зауровна, кандидат технических наук, доцент кафедры прикладной математики и компьютерного моделирования, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Krivchikova Anastasia Sergeyevna, middle software engineer, SoftTrust Ltd, Belgorod, Russia

Bolgova Evgenia Vitalyevna, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Applied Informatics and Information Technologies, Belgorod State National Research University, Belgorod, Russia

Chernomorets Andrey Alekseyevich, Doctor of Technical Sciences, Associate Professor, Professor of the Department of Applied Informatics and Information Technologies, Belgorod State National Research University, Belgorod, Russia

Yaduta Anna Zaurovna, Candidate of Technical Sciences, Associate Professor of the Department of Applied Mathematics and Computer Modeling, Belgorod State National Research University, Belgorod, Russia

УДК 519.86

DOI: 10.18413/2518-1092-2026-11-2-0-2

Федоров М.В.
Королев В.А.

СРАВНИТЕЛЬНЫЙ АНАЛИЗ РАЗЛИЧНЫХ МЕТОДОВ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ ПОЛИТИЧЕСКОЙ ДИНАМИКИ НА ОСНОВЕ ТЕОРИИ МНОГОПОТОЧНОСТИ

Институт проблем передачи информации им. А.А. Харкевича Российской Академии Наук,
Большой Каретный переулок, д.19 стр. 1., Москва, 127051, Россия

e-mail: korolev.va@iitp.ru

Аннотация

В статье рассматривается проблема анализа и прогнозирования состояний политической системы на основе теории многопоточности (Multiple Streams Framework) Джона Кингдона. Политическая безопасность определяется как состояние стабильности политической активности, границы которой определяются стабильным и турбулентным режимами. Для моделирования взаимодействия потоков проблем, политических решений и политических условий предлагается применение методов нечёткой логики, теории катастроф и теории перколяции. Каждый из методов позволяет анализировать различные аспекты политической динамики. Нечёткая логика позволяет моделировать процессы принятия решений в условиях неопределённости, теория катастроф позволяет исследовать политическое состояние в точках бифуркаций (окон возможностей), а перколяция позволяет изучать фазовые переходы в политической системе. Разработаны соответствующие математические модели, проведён их сравнительный анализ. Статья также вводит понятия «политической температуры» и «усталости системы», предлагая направления для дальнейших исследований.

Ключевые слова: политическая безопасность; теория многопоточности; окно возможностей; нечёткая логика; теория катастроф; перколяция; политическая турбулентность; системы поддержки принятия решений

Для цитирования: Федоров М.В., Королев В.А. Сравнительный анализ различных методов математического моделирования политической динамики на основе теории многопоточности // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 14-25. DOI: 10.18413/2518-1092-2026-11-2-0-2

Fedorov M.V.
Korolev V.A.

COMPARATIVE ANALYSIS OF DIFFERENT METHODS OF MATHEMATICAL MODELING OF POLITICAL DYNAMICS BASED ON THE MULTIPLE STREAMS FRAMEWORK

Kharkevich Institute for Information Transmission Problems, Russian Academy of Sciences,
19 Bolshoy Karetny per., Moscow, 127051, Russia

e-mail: korolev.va@iitp.ru

Abstract

This article examines the problem of analyzing and forecasting the states of the political system based on John Kingdon's Multiple Streams Framework. Political security is defined as a state of stability in political activity, the boundaries of which are determined by stable and turbulent regimes. To model the interaction among the problem stream, policy stream, and politics stream, the application of fuzzy logic, catastrophe theory, and percolation theory is proposed. Each of these methods enables the analysis of different aspects of political dynamics. Fuzzy logic allows for the modeling of decision-making processes under conditions of uncertainty; catastrophe theory facilitates the investigation of the political state at bifurcation points (policy windows); and percolation theory enables the study of phase transitions within the political system. Corresponding mathematical models are developed, and a comparative analysis of these models is conducted. The

article also introduces the concepts of “political temperature” and “system fatigue,” outlining directions for further research.

Keywords: political security; Multiple Streams Framework; policy window; fuzzy logic; catastrophe theory; percolation; political turbulence; decision support systems

For citation: Fedorov M.V., Korolev V.A. Comparative Analysis of Different Methods of Mathematical Modeling of Political Dynamics Based on the Multiple Streams Framework // Research result. Information technologies. – Т.11, №2, 2026. – P. 14-25. DOI: 10.18413/2518-1092-2026-11-2-0-2

ВВЕДЕНИЕ

Политические процессы характеризуются высокой степенью неопределённости и динамичности. Актуальной задачей является разработка инструментов, позволяющих анализировать и прогнозировать состояние политической системы для обеспечения её стабильности. В данной работе политическая безопасность понимается как состояние системы, обеспечиваемое комплексом мер, направленных на стабилизацию политической активности, границы которой определяются стабильным и турбулентным состояниями. Стабильное состояние характеризуется отсутствием среды для политической напряжённости, в то время как турбулентное состояние запускает поток проблем и усиливает напряжённость в обществе.

В качестве теоретической основы используется теория многопоточности (Multiple Streams Framework, MSF), разработанная Джоном Кингдоном [1]. Согласно этой теории, формирование политической повестки происходит в результате взаимодействия трёх независимых потоков: проблем (Problem Stream), политических решений (Policy Stream) и политических условий (Political Stream). Соединение элементов этих потоков в определённый момент времени создаёт «окно возможностей» (Policy Window) или точку бифуркации, которая может привести как к укреплению, так и к дестабилизации политической системы.

Целью данного исследования является разработка математической модели, позволяющей анализировать гетерогенные потоки данных для систем поддержки принятия политических решений. Для этого рассматриваются и сравниваются три математических аппарата: нечёткая логика, теория катастроф и теория перколяции. [2-6]

1. ТЕОРЕТИЧЕСКАЯ ОСНОВА: ТЕОРИЯ МНОГОПОТОЧНОСТИ КИНГДОНА




Рис. Общая схема теории сложных потоков
Fig. General scheme of the theory of complex flows

Теория Кингдона постулирует, что процесс формирования политики происходит в трёх потоках (см. рисунок):

1. Поток проблем (Problem Stream) представляет собой совокупность вопросов, воспринимаемых обществом и политическими акторами как требующие государственного реагирования. Формирование данного потока осуществляется под влиянием объективных индикаторов (статистические данные, отчеты), знаковых событий, а также обратной связи от реализации предыдущих политических курсов. Важно отметить, что Кингдон различает собственно

«проблемы», которые субъективно определяются как требующие решения, и «условия» – объективно существующие, но не получающие статуса проблем в публичной повестке.

2. Поток политических решений (Policy Stream) составляет совокупность идей, концепций и готовых проектов решений, разрабатываемых и продвигаемых сообществом экспертов, аналитиков, лоббистов и заинтересованных групп. Решения из этого потока циркулируют в так называемой «первичной политике», конкурируя между собой по критериям технической осуществимости, соответствия ценностям и приемлемости с точки зрения затрат.

3. Поток политических условий (Political Stream) формируется под воздействием факторов системного уровня: общенационального настроения, результатов выборов, идеологического состава законодательных органов, активности групп интересов. Данный поток характеризует общую политическую конъюнктуру, определяющую границы возможного в конкретный временной период.

Ключевую роль в соединении элементов этих потоков играют политические предприниматели (Policy Entrepreneurs), далее в работе мы будем называть их политическими сообществами – акторы, активно продвигающие определенные проблемы и решения в повестке дня. Их деятельность направлена на использование благоприятного стечения обстоятельств для легитимации своих предложений.

Совпадение элементов трех потоков, а именно (i) признания проблемы, (ii) наличия готового решения и (iii) благоприятной политической конъюнктуры приводит к открытию «окна возможностей». Это кратковременный период, когда вероятность значительных политических изменений многократно возрастает. В терминах синергетики, данное состояние системы идентифицируется как точка бифуркации, в которой малые воздействия могут привести к макроскопическим последствиям – как к стабилизации, так и к дестабилизации политического режима [5].

В условиях стабильной политической системы эти три потока функционируют в режиме рутинного управления, при котором возникающие проблемы решаются в рамках существующих институциональных процедур. Однако активизация политических сообществ, целенаправленно стремящихся к изменению приоритетов повестки дня, может нарушить данное равновесие. Их деятельность, направленная на переоценку значимости определенных явлений и искусственное соединение элементов потоков, является одним из ключевых факторов возникновения политической турбулентности.

Таким образом, задача математического моделирования в данном контексте заключается в формализации условий возникновения «окна возможностей», идентификации аномальных паттернов во взаимодействии потоков, вызванных целенаправленными действиями акторов, и разработке критериев дифференциации между нормальным и турбулентным состояниями политической системы.

2. МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ ПОЛИТИЧЕСКОЙ СИСТЕМЫ

2.1. Моделирование на основе нечёткой логики

Для формализации процессов принятия решений в условиях неопределённости, характерных для политической сферы, предлагается применение математического аппарата нечёткой логики. Данный метод позволяет оперировать лингвистическими переменными и качественными оценками, что адекватно отражает природу политических процессов, характеризующихся высокой степенью субъективности и недостаточностью точных количественных данных. [4]

2.1.1 Формализация потоков как лингвистических переменных

В рамках модели каждый из трёх потоков теории Кингдона формализуется как лингвистическая переменная, значениями которой являются нечёткие множества.

Определение нечётких множеств

Каждый поток описывается нечёткими переменными, которые являются функциями принадлежности. Допустим поток проблем будет $P(x)$, поток политических решений $I(y)$, поток политических условий $C(z)$, $D(w)$ – состояние окна возможностей.

Поток проблем (P):

- $\mu_P(x)$ – степень принадлежности проблемы x к множеству «важных проблем».
- Пример: «Высокая важность», «Средняя важность», «Низкая важность».

Поток политических решений (I):

- $\mu_I(y)$ – степень принадлежности решения y к множеству «готовых решений».
- Пример: «Высокая готовность», «Средняя готовность», «Низкая готовность».

Поток политических условий (C):

- $\mu_C(z)$ – степень принадлежности политического условия z к множеству «благоприятных условий».
- Пример: «Высокая благоприятность», «Средняя благоприятность», «Низкая благоприятность».

Окно возможностей (W):

- $\mu_D(w)$ – степень принадлежности окна возможностей w к множеству «состояние окна».
- Пример: «Окно открыто», «Окно может открыться в скором времени», «Окно закрыто».

Нечёткие правила взаимодействия потоков

Опишем взаимодействие потоков с помощью нечётких правил, которые определяют, как сочетание проблем, политических решений и политических возможностей приводит к «окнам возможностей». Пример правил:

1. **ЕСЛИ** проблема «высокой важности» **И** решение «высокой готовности» **И** политика «высокой благоприятности», **ТО** окно возможностей «открыто».
2. **ЕСЛИ** проблема «средней важности» **И** решение «средней готовности» **И** политика «средней благоприятности», **ТО** окно возможностей «Окно может открыться в скором времени».
3. **ЕСЛИ** проблема «низкой важности» **ИЛИ** решение «низкой готовности» **ИЛИ** политика «низкой благоприятности», **ТО** окно возможностей «закрыто».

Эти правила можно записать в следующем виде:

$$R_i: \text{ЕСЛИ } \mu_P(x) = A_i \text{ И } \mu_I(y) = B_i \text{ И } \mu_C(z) = C_i \text{ ТО } \mu_W = D_i$$

где:

- A_i, B_i, C_i – нечёткие множества для проблем, решений и политики,
- D_i – нечёткое множество для окна возможностей,
- μ_W – степень принадлежности к окну возможностей.
- μ_P – степень принадлежности к множеству проблем.
- μ_I – степень принадлежности к множеству решения.
- μ_C – степень принадлежности к множеству политических условий.

Агрегация нечётких правил

Для каждого правила вычисляется степень активации (t-норма)

$$\alpha_i = \min(\mu_P(x), \mu_I(y), \mu_C(z)).$$

Затем результаты всех правил агрегируются (s-норма)

$$\mu_W(w) = \max(\alpha_1 * D_1(w), \alpha_2 * D_2(w), \dots, \alpha_n D_n(w)),$$

где w – степень открытость окна возможностей.

Дефаззификация

Чтобы получить чёткое значение для окна возможностей, необходимо выполнить дефаззификацию различными методами [7]. Например, можно использовать метод центра тяжести.

$$w^* = \frac{\int w * \mu_w(w)dw}{\int \mu_w(w)dw},$$

где w^* – чёткое значение степени открытости окна.

Определение функции принадлежности

Функции принадлежности для потока проблем Р

Пусть x – степень важности проблемы от 0 до 10, определим три нечётких множества:
Низкая важность (A_1):

$$\mu_{A_1}(x) = \begin{cases} 1 - \frac{x}{2}, & 0 \leq x \leq 2, \\ 0, & x > 2 \end{cases}$$

Средняя важность (A_2):

$$\mu_{A_2}(x) = \begin{cases} \frac{x-1}{2}, & \text{при } 1 \leq x \leq 3 \\ \frac{7-x}{2}, & \text{при } 5 < x < 7 \\ 0, & \text{при } x > 7 \\ 1, & \text{при } 5 < x \leq 7 \end{cases}$$

Высокая важность (A_3):

$$\mu_{A_3}(x) = \begin{cases} \frac{x-6}{2}, & 6 \leq x \leq 8 \\ 0, & x \leq 6 \\ 1, & x > 8 \end{cases}$$

Функции принадлежности для потока решений I

Пусть y – степень важности проблемы от 0 до 10, определим три нечётких множества:
Низкая готовность (B_1):

$$\mu_{B_1}(y) = \begin{cases} 1 - \frac{y}{3}, & 0 \leq x \leq 3, \\ 0, & x > 3. \end{cases}$$

Средняя готовность (B_2):

$$\mu_{B_2}(y) = \begin{cases} \frac{y-2}{2}, & \text{при } 2 \leq x \leq 4 \\ \frac{8-y}{2}, & \text{при } 6 < x \leq 8 \\ 0, & \text{при } x > 8 \\ 1, & \text{при } 4 < x \leq 6 \end{cases}$$

Высокая готовность (B_3):

$$\mu_{B_3}(y) = \begin{cases} \frac{y-5}{3}, & 5 < y \leq 8 \\ 0, & y \leq 5 \\ 1, & y > 8 \end{cases}$$

Функции принадлежности для потока политических возможностей С

Пусть z – степень благоприятности политических возможностей от 0 до 10, определим три нечётких множества:

Низкая благоприятность (C_1):

$$\mu_{C_1}(z) = \begin{cases} 1 - \frac{z}{4}, & 0 \leq z \leq 4, \\ 0, & z > 4. \end{cases}$$

Средняя благоприятность (C_2):

$$\mu_{C_2}(z) = \begin{cases} \frac{z-3}{2}, & \text{при } 3 \leq z \leq 5 \\ \frac{9-z}{2}, & \text{при } 7 < z < 9 \\ 0, & \text{при } z > 9 \\ 1, & \text{при } 5 < z \leq 7 \end{cases}$$

Высокая благоприятность (C_3):

$$\mu_{C_3}(z) = \begin{cases} \frac{z-6}{2}, & 6 < z \leq 8 \\ 0, & z \leq 6 \\ 1, & z > 8 \end{cases}$$

Функции принадлежности для состояний окна возможностей W

Пусть w – степень открытости окна возможностей (например, от 0 до 1). Определим три нечётких множества:

Окно закрыто (D_1):

$$\mu_{D_1}(w) = \begin{cases} 1 - 5w, & 0 \leq w \leq 0.2, \\ 0, & z > 0.2. \end{cases}$$

Окно в скором времени может открыться (D_2):

$$\mu_{D_2}(w) = \begin{cases} 5w, & \text{при } 0 \leq w \leq 0.2 \\ \frac{1-w}{0.4}, & \text{при } 0.6 < w \leq 1 \\ 1, & \text{при } 0.2 < w \leq 0.6 \end{cases}$$

Окно открыто (D_3):

$$\mu_{D_3}(w) = \begin{cases} \frac{w-0.5}{0.3}, & 0.5 < z \leq 0.8 \\ 0, & w \leq 0.5 \\ 1, & w > 0.8 \end{cases}$$

Пример

Рассмотрим пример, чтобы понять, как работает наша модель. Предположим, что:

- Проблема имеет степень важности $x=7$.
- Решение имеет степень готовности $y=6$.
- Политика имеет степень благоприятности $z=8$.

Вычисление степени принадлежности:

1. Для потока проблем: $\mu_{A_1}(7) = 0, \mu_{A_2}(7) = 0, \mu_{A_3}(7) = 0.5$
2. Для потока решений: $\mu_{B_1}(6) = 0, \mu_{B_2}(6) = 1, \mu_{B_3}(6) = 0.33$
3. Для потока политических условий: $\mu_{C_1}(8) = 0, \mu_{C_2}(8) = 0.5, \mu_{C_3}(8) = 1$

Применение нечётких правил:

1. ЕСЛИ проблема «высокой важности» (A_3) И решение «высокой готовности» (B_3) И политика «высокой благоприятности» (C_3), ТО окно возможностей «Открыто» (D_3).
2. ЕСЛИ проблема «средней важности» (A_2) И решение «средней готовности» (B_2) И политика «средней благоприятности» (C_2), ТО окно возможностей «скоро откроется» (D_2).
3. ЕСЛИ проблема «низкой важности» (A_1) ИЛИ решение «низкой готовности» (B_1) ИЛИ политика «низкой благоприятности» (C_1), ТО окно возможностей «Закрыто» (D_1).

Вычисление степени активации для каждого правила, t-нормы и s-нормы.

Для правила 1

$$\alpha_1 = \min(\mu_{A_3}(7), \mu_{B_3}(6), \mu_{C_3}(8)) = \min(0.5, 0.33, 1) = 0.33$$

Для правила 2

$$\alpha_2 = \min(\mu_{A_2}(7), \mu_{B_2}(6), \mu_{C_2}(8)) = \min(0, 1, 0.5) = 0$$

Для правила 3

$$\alpha_3 = \max(\mu_{A_1}(7), \mu_{B_1}(6), \mu_{C_1}(8)) = \max(0, 0, 0) = 0$$

Агрегация результатов

Результаты правил агрегируются с использованием операции максимума:

$$\mu_W(w) = \max(\alpha_1 * D_3(w), \alpha_2 * D_2(w), \alpha_3 * D_1(w))$$

Подставляем наши значения:

$$\mu_W(w) = \max(0.33 * D_3(w), 0 * D_2(w), 0 * D_1(w)) = 0.33 * D_3(w)$$

Дефазификация

Для дефазификации используем метод центра тяжести, функция принадлежности для «Открыто» D_3 определена как:

$$\mu_{D_3}(w) = \begin{cases} \frac{w - 0.5}{0.3}, & 0.5 < w \leq 0.8 \\ 0, & w \leq 0.5 \\ 1, & w > 0.8 \end{cases}$$

Так как $\mu_W(w) = 0.33 * D_3(w)$, то функция принадлежности для окна возможностей:

$$\mu_{D_3}(w) = \begin{cases} 0.33 * \frac{w - 0.5}{0.3}, & 0.5 < w \leq 0.8 \\ 0, & w \leq 0.5 \\ 0.33, & w > 0.8 \end{cases}$$

Вычисление центра тяжести

$$w^* = \frac{\int_{0.5}^{0.8} w * 0.33 * \frac{w-0.5}{0.3} dw + \int_{0.8}^1 w * 0.33 dw}{\int_{0.5}^{0.8} 0.33 * \frac{w-0.5}{0.3} dw + \int_{0.8}^1 0.33 dw} = \frac{0.2243}{0.1155} \approx 1.94$$

Так как у нас значение от 0 до 1 включительно, то значение $w^* = 1$, максимальная открытость.

2.2. Моделирование на основе теории катастроф

Для анализа критических переходов политической системы между качественно различными состояниями (стабильность – турбулентность) применяется математический аппарат теории катастроф. Данный метод позволяет исследовать поведение нелинейных динамических систем, в которых плавное изменение управляющих параметров может вызывать скачкообразные изменения состояния системы (катастрофы). [8]

2.2.1 Теоретико-катастрофическая интерпретация модели

В контексте данного исследования «окно возможностей» идентифицируется как точка бифуркации, то есть момента потери системой структурной устойчивости, когда её дальнейшая эволюция становится принципиально неоднозначной. Синергетический подход позволяет интерпретировать политическую систему как нелинейную среду, где малые воздействия в окрестности точек бифуркации могут привести к макроскопическим последствиям (аттракторам развития). [5,8]

Катастрофа – резкое изменение состояния системы, вызванное плавным изменением некоторых параметров системы.

Бифуркация – точка, в которой система переходит из одного состояния в другое.

Потенциальная функция – это функция, которая описывает изменение системы. Бифуркация – это точки, в которых потенциальная функция имеет особенности – экстремумы или разрывы.

В терминах теории катастроф, точка бифуркации в многопоточной системе Кингдона – это окно возможностей. Благодаря моделированию данным методом мы сможем проанализировать такие точки, где небольшие изменения в параметрах приводят к значительным изменениям в системе в целом. Эти окна могут быть интерпретированы как катастрофы, где система переходит из одного состояния (стабильность) в другое (турбулентность).

2.2.2 Формальная параметризация модели

Поведение системы описывается набором управляющих (внешних) параметров, соответствующих потокам Кингдона, и одной фазовой переменной, характеризующей состояние системы:

Определение параметров системы:

- Проблемы (Р): Уровень важности проблемы (х).
- Политические решения (I): Готовность решений (у).
- Политические условия (С): Благоприятность условий (z).
- Окно возможностей (W): Состояние системы (стабильное или турбулентное).

Потенциальная функция:

• Потенциальная функция системы может быть определена как функция, зависящая от параметров Р, I и С. Например:

$$V(x, y, z) = ax^2 + by^2 + cz^2 + dxy + exz + fyz,$$

где a, b, c, d, e, f – коэффициенты, определяющие взаимодействие потоков.

Как мы уже сказали, точки бифуркации возникают, когда потенциальная функция имеет особенности. Например, при определённых значениях параметров система может перейти из стабильного состояния в турбулентное.

В контексте политической системы, это может быть момент, когда проблема становится настолько важной, что требует немедленного решения, или когда политические условия становятся настолько благоприятными, что открывается окно возможностей.

Одной из наиболее распространённых моделей в теории катастроф является катастрофа типа «сборка». [5,8] Она описывает систему с двумя устойчивыми состояниями, между которыми может происходить резкий переход. В контексте политической системы, катастрофа «сборка» может быть использована для моделирования перехода между стабильным и турбулентным состояниями.

Уравнение катастрофы вида «сборка» $V(x) = \frac{1}{4}x^4 - \frac{1}{2}ax^2 - bx$, где x – состояние системы, a и b – параметры, определяющие поведение системы.

В нашем случае, можно говорить о том, что параметр a отражает уровень политической напряжённости, параметр b – уровень готовности решений. При низких значениях a и b система находится в стабильном состоянии.

При увеличении a (уровень напряжённости) система может резко перейти в турбулентное состояние, даже если b (готовность решений) изменяется плавно.

2.3. Моделирование на основе теории перколяции

Теория перколяции [3] изучает возникновение связанных структур (кластеров) в случайных средах и моделирует фазовые переходы второго рода. Политическая система представляется в виде графа, где узлы – это акторы или события, а рёбра – связи между ними.

С точки зрения синергетики [5], теория перколяции является мощным инструментом для анализа фазовых переходов в сложных системах, где кооперативное поведение элементов приводит к макроскопическим изменениям. Малинецкий в монографии [5] отмечает, что такие переходы часто носят пороговый характер и могут быть интерпретированы как «точки обострения», в которых

система переходит в качественно новое состояние. В политическом контексте это соответствует внезапному распространению протестных настроений или идей – формированию «гигантского кластера» общественного запроса, который система уже не может игнорировать. Это позволяет моделировать не только сам факт открытия «окна возможностей», но и скорость распространения турбулентности в политическом пространстве.

Математический метод перколяции позволяет моделировать фазовые переходы системы, при которых система приобретает качественно новые свойства при малом изменении параметров или иначе – позволяет моделировать процесс, при котором плавное изменение параметров системы приводит к скачкообразному изменению системы.

Фазовые переходы

Как было сказано выше, в терминах термодинамики, теория перколяции рассматривает фазовые переходы второго рода, поскольку фазовый переход первого рода предполагает переход системы из одного агрегатного состояния в другое, к примеру – замерзание воды, плавление металла и прочее. [3] Согласно принятым определениям, фазовый переход первого порядка – равновесный переход вещества из одной фазы в другую, в котором скачкообразно изменяются первые производные функции по температуре и давлению.

Фазовый переход второго рода не предполагает изменения агрегатного состояния системы, а только внутренних свойств, к примеру, переход металлов и сплавов в состояние сверхпроводимости, переход парамагнетик-ферромагнетик. Фазовый переход второго порядка – это такой переход, при котором вторые производные термодинамических потенциалов по давлению и температуре изменяются скачкообразно.

Основные понятия

Как правило такую систему описывают либо как решетку, либо как граф $G=(V,E)$, где V – множество вершин(узлов), а E – множество ребёр (связей)

Такая система имеет порог перколяции – это такая вероятность p_c при которой возникает бесконечный кластер, иначе «система протекает».

- При $p < p_c$ – только изолированные кластеры.
- При $p > p_c$ – возникает гигантский связный кластер.

Кластер – это связный подграф, с математической точки зрения это связанное подмножество всех вершин решётки.

К примеру, разберём модель лесного пожара, таким образом у нас получается:

Модель: Рёберная перколяция на квадратной решётке.

Параметры:

- p – вероятность того, что участок леса не выгорел.
- $p_c \approx 0.5927$ (для квадратной решётки).

Сценарий:

- При $p < p_c$ огонь гаснет, не охватив весь лес.
- При $p > p_c$ пожар охватывает бесконечную область.

3. СРАВНИТЕЛЬНЫЙ АНАЛИЗ МАТЕМАТИЧЕСКИХ МОДЕЛЕЙ

Нечёткая логика, теория катастроф и перколяция дополняют друг друга: первая описывает процессы принятия решений в условиях неопределённости, вторая – критические точки развития, третья – механизмы распространения изменений. Комплексное использование этих методов позволяет перейти от описания отдельных феноменов к построению прогнозных моделей, способных учитывать нелинейность и многоуровневость политических процессов.

В таблице представлено сравнение рассмотренных методов по ключевым критериям.

Таблица

Сравнительный анализ математических моделей для теории Кингдона

Table

Comparative analysis of mathematical models for Kingdon's theory

Критерий	Метод нечёткой логики	Теория катастроф	Теория перколяции
Тип данных	Работает с нечёткими данными	Требуется точные количественные данные	Работает с вероятностными и сеточными данными
Динамика системы	Подходит для анализа взаимодействия потоков	Подходит для анализа резких изменений (бифуркаций)	Подходит для анализа фазовых переходов и распространения турбулентности
Окно возможностей	Моделируется через нечёткие правила	Моделируется в поведении системы в точке бифуркации	Моделируется как момент достижения порога перколяции, когда возникает «гигантский кластер» проблемы или недовольства
Гибкость	Высокая. Позволяет легко добавлять новые лингвистические переменные и правила	Средняя. Зависит от выбранного типа катастрофы; сложно масштабировать на более чем 2-3 управляющих параметра	Высокая Позволяет моделировать системы с разной топологией (решётки, случайные графы, масштабно-свободные сети)
Применимость	Подходит для анализа процессов принятия решений	Подходит для анализа кризисов и переходов между состояниями	Подходит для анализа устойчивости системы к каскадным процессам (распространение протестов, информационных кампаний)

ЗАКЛЮЧЕНИЕ И ДАЛЬНЕЙШИЕ ИССЛЕДОВАНИЯ

В работе проведён анализ возможности применения трёх математических аппаратов нечёткой логики, теории катастроф и теории перколяции для моделирования политических процессов в рамках теории Кингдона. Каждый из методов имеет свою нишу:

- Нечёткая логика эффективна для моделирования процессов принятия решений в условиях неопределённости.
- Теория катастроф позволяет анализировать критические точки (бифуркации) в развитии политической системы.

• Теория перколяции даёт инструментарий для оценки устойчивости системы к распространению турбулентности.

Для создания комплексной системы поддержки принятия решений целесообразно комбинирование этих подходов. В качестве направлений для дальнейших исследований предлагается:

1. Формализация понятий «политическая температура» и «усталость политической системы» по аналогии с материаловедением.

2. Выявление и классификация атрибутов политической турбулентности (демография, экономические показатели, медиа-активность и др.).

3. Разработка интегральной модели, сочетающей сильные стороны рассмотренных методов для многомасштабного анализа (от локального до национального уровня).

Перспективным направлением является разработка вычислительных моделей политической динамики, позволяющих проводить эксперименты в виртуальной среде, что включает в себя:

• Анализ сценариев развития политической системы при варьировании ключевых параметров («политической температуры», уровня напряжённости, активности медиа).

• Идентификация аттракторов – устойчивых состояний системы, к которым она стремится вернуться после возмущений.

• Моделирование нелинейных обратных связей, усиливающих или ослабляющих политическую турбулентность.

Такой подход позволит не только прогнозировать кризисы, но и оценивать эффективность управляющих воздействий, направленных на стабилизацию системы.

Список литературы

1. Kingdon J.W. Agendas, Alternatives, and Public Policies. – Boston: Little, Brown, 1984. – 240 p.
2. Thom R. Structural Stability and Morphogenesis: An Outline of a General Theory of Models / Translated by D.H. Fowler. – Reading, Mass.: W.A. Benjamin, 1975. – 348 p.
3. Меньшиков М.В., Молчанов С.А., Сидоренко А.Ф. Теория перколяции и некоторые приложения // Итоги науки и техники. Сер. Теор. вероятн. Мат. статист. Теор. кибернет. – 1986. – Т. 24. – С. 53–110.
4. Заде Л.А. Понятие лингвистической переменной и его применение к принятию приближённых решений. – М.: Мир, 1976. – 168 с.
5. Малинецкий Г.Г. Математические основы синергетики: Хаос, структуры, вычислительный эксперимент. – 6-е изд. – М.: Книжный дом «ЛИБРОКОМ», 2009. – 312 с.
6. Пегат А. Нечеткое моделирование и управление / А. Пегат, А. Г. Подвесовский, Ю. В. Тюменцев. – 3-е изд. (эл.). – М.: Бином. Лаборатория знаний, 2015. – 801 с. – (Адаптивные и интеллектуальные системы).
7. Демидова Г.Л., Лукичев Д.В. Регуляторы на основе нечеткой логики в системах управления техническими объектами. – СПб: Университет ИТМО, 2017. – 81 с.
8. Арнольд В.И. Теория катастроф, Москва, «Наука», 1990. – 128 с.

References

1. Kingdon J.W. Agendas, Alternatives, and Public Policies. – Boston: Little, Brown, 1984. – 240 p.
2. Thom R. Structural Stability and Morphogenesis: An Outline of a General Theory of Models / Translated by D.H. Fowler. – Reading, Mass.: W.A. Benjamin, 1975. – 348 p.
3. Menshikov M.V., Molchanov S.A., Sidorenko A.F. Percolation Theory and Some Applications // Itogi Nauki i Tekhniki. Ser. Teor. Veroyatn. Mat. Stat. Teor. Kibernet. – 1986. Vol. 24, pp. 53–110.
4. Zadeh L.A. The Concept of a Linguistic Variable and Its Application to Approximate Reasoning. – M.: Mir, 1976. – 168 p.
5. Malinetsky G.G. Mathematical Foundations of Synergetics: Chaos, Structures, Computational Experiment, 6th ed. Moscow: LIBROKOM Publishing House, 2009. – 312 p.
6. Pegat A. Fuzzy Modeling and Control / A. Pegat, A.G. Podvesovsky, Yu.V. Tyumentsev. – 3rd ed. (el.). – M.: Binom. Laboratory of knowledge, 2015. – 801 p. – (Adaptive and intelligent systems).
7. Demidova G.L., Lukichev D.V. Fuzzy Logic Controllers in Technical Object Control Systems. – St. Petersburg: ITMO University, 2017. – 81 p.
8. Arnold V.I. Catastrophe Theory. Moscow: Nauka, 1990. – 128 p.

Федоров Максим Валериевич, доктор химических наук, член-корреспондент РАН, и.о. директора, Институт проблем передачи информации им. А.А. Харкевича Российской Академии Наук, г. Москва, Россия

Королев Всеволод Алексеевич, аспирант, Институт проблем передачи информации им. А.А. Харкевича Российской Академии Наук, г. Москва, Россия

Fedorov Maxim Valerievich, Doctor of Chemical Sciences, Corresponding Member of the Russian Academy of Sciences, Acting Director, Kharkevich Institute for Information Transmission Problems, Russian Academy of Sciences, Moscow, Russia

Korolev Vsevolod Alekseyevich, Postgraduate Student, Kharkevich Institute for Information Transmission Problems, Russian Academy of Sciences, Moscow, Russia

УДК 004.891.2

DOI: 10.18413/2518-1092-2026-11-2-0-3

Левина Т.М.
Альмухаметова Э.И.
Чудаков Н.М.

**ЛИНЕЙНАЯ И ПОЛИНОМИАЛЬНАЯ РЕГРЕССИЯ
КАК ИНСТРУМЕНТЫ АНАЛИЗА ИСТОРИЧЕСКИХ ДАННЫХ
В ЗАДАЧАХ НЕФТЕПЕРЕРАБОТКИ**

Институт нефтепереработки и нефтехимии ФГБОУ ВО УГНТУ в г. Салавате,
ул. Губкина, 22Б, г. Салават, 453250, Россия

e-mail: tattin76@mail.ru

Аннотация

В статье исследуется применение регрессионных методов (линейной и полиномиальной регрессии) для прогнозирования технологических параметров в нефтегазовой отрасли. Актуальность работы обусловлена потребностью в точных инструментах прогнозирования, позволяющих оптимизировать управление нефтеперерабатывающими установками и снижать риски отклонений от нормативных режимов. Методология исследования включает анализ исторических данных. Практическая реализация выполнена с использованием веб технологий. Программная архитектура построена по клиент серверному принципу, что обеспечивает масштабируемость и безопасность системы. В результате сформированы математические модели для трёх ключевых параметров нефтепереработки, реализована веб платформа с интерактивными графиками и подтверждена возможность интеграции решений в промышленную среду на базе отечественной операционной системы. Сделан вывод, что линейная и полиномиальная регрессия – эффективные инструменты анализа исторических данных и прогнозирования технологических параметров. Результаты исследования обеспечивают наглядность, кроссплатформенность и надёжность, что делает его перспективным для внедрения в производственные процессы нефтепереработки.

Ключевые слова: линейная регрессия; полиномиальная регрессия; прогнозирование технологических параметров; нефтегазовая отрасль; математическая модель; клиент серверная архитектура; визуализация данных; библиотека построения графиков

Для цитирования: Левина Т.М., Альмухаметова Э.И., Чудаков Н.М. Линейная и полиномиальная регрессия как инструменты анализа исторических данных в задачах нефтепереработки // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 26-35. DOI: 10.18413/2518-1092-2026-11-2-0-3

Levina T.M.
Almukhametova E.I.
Chudakov N.M.

**LINEAR AND POLYNOMIAL REGRESSION AS TOOLS FOR
HISTORICAL DATA ANALYSIS IN OIL REFINING PROBLEMS**

Institute of Oil Refining and Petrochemistry
Federal State Budgetary Educational Institution of Higher Education USPTU in Salavat,
22B Gubkin St., Salavat, 453250, Russia

e-mail: tattin76@mail.ru

Abstract

The article examines the application of regression methods (linear and polynomial regression) for predicting technological parameters in the oil and gas industry. The relevance of the study stems from the need for accurate forecasting tools that help optimize the control of oil refining units and reduce the risks of deviations from standard operating modes.

The research methodology includes the analysis of historical data. The practical implementation was carried out using web technologies. The software architecture follows a client server approach, which ensures the system's scalability and security.

As a result, mathematical models were developed for three key parameters of oil refining, an interactive web platform with graphs was implemented, and the feasibility of integrating the solutions into an industrial environment based on a domestic operating system was confirmed. It is concluded that linear and polynomial regression are effective tools for analyzing historical data and predicting technological parameters. The research results provide clarity, cross platform compatibility, and reliability, making the solution promising for implementation in oil refining production processes.

Keywords: linear regression; polynomial regression; technological parameter forecasting; oil and gas industry; mathematical model; client server architecture; data visualization; charting library

Forcitation: Levina T.M., Almukhametova E.I., Chudakov N.M. Linear and Polynomial Regression as Tools for Historical Data Analysis in Oil Refining Problems // Research result. Informationtechnologies. – Т.11, №2, 2026. – P. 26-35. DOI: 10.18413/2518-1092-2026-11-2-0-3

ВВЕДЕНИЕ

В последние годы наблюдается рост числа аварий и инцидентов в нефтегазовой отрасли. По данным Росстата, в 2022 году в России произошло более 150 аварий на нефтегазовых объектах, что на 20% больше по сравнению с 2021 годом [1]. Значительная доля инцидентов была связана с отклонениями от технологических режимов, а экономические потери оцениваются в десятки миллиардов рублей [2]. В связи с этим решение задач прогнозирования режимов работы, а также принятия решений на их основе за счет внедрения современных цифровых решений становится актуальной задачей.

Одним из главных инструментов для этого является разработка специализированного программного обеспечения, основанного на анализе исторических данных, которое позволяет прогнозировать получение продукции требуемого качества и обеспечивает возможность регулирования важных технологических параметров [3]. Стратегически важным решением является создание такого программного обеспечения (ПО) на базе отечественной операционной системы РЕД ОС, что обусловлено задачами обеспечения технологического суверенитета [4].

Использование отечественной платформы позволяет снизить зависимость от зарубежных программных решений, что играет большую роль для объектов нефтегазовой инфраструктуры.

ОСНОВНАЯ ЧАСТЬ

Существует множество методов обработки исторических данных используемых в математических моделях для прогнозирования технологических режимов работы установок в нефтегазовой отрасли. Понимание методов обработки данных и составление математических моделей на их основании является ключевым фактором для успешной реализации программного обеспечения и достижения высоких результатов в прогнозировании свойств технологических процессов [5].

Математическая модель линейной регрессии, это статистический метод, который используется для моделирования зависимости между одной зависимой переменной и одной или несколькими независимыми переменными [6]. Модель предполагает, что существует линейная связь между входными параметрами и целевыми свойствами, может быть представлена в виде уравнения:

$$y = b_0 + b_1 \cdot x_1 + b_2 \cdot x_2 + \dots + b_n \cdot x_n,$$

где y – предсказываемая переменная; b_0 – свободный член; $b_1, b_2, \dots, b_n$ – коэффициенты регрессии; $x_1, x_2, \dots, x_n$ – независимые переменные.

Преимуществами модели линейной регрессии, являются простота и интерпретируемость; быстрота обучения и предсказания. Недостатками: чувствительность к выбросам; невозможность моделирования нелинейных зависимостей без дополнительных преобразований [7].

Так же, для обработки большого количества данных, существует метод полиномиальной регрессии. **Полиномиальная регрессия** – статистический метод анализа данных, позволяющий моделировать нелинейные зависимости между переменными с помощью полиномиальных функций [8]. Это расширение линейной регрессии, способное описывать более сложные закономерности в многомерных наборах данных.

Его применение логично в том случае, когда связь между независимой переменной (входной) и зависимой переменной (выходной) нелинейная. Суть полиномиальной регрессии – **расширение линейной модели путём добавления новых признаков**. Если есть один исходный признак x , в модель добавляют его степени: x^2 , x^3 и так далее, до некоторой степени n . Если признаков несколько (x_1 , x_2 и т.д.), то помимо степеней каждого признака, добавляют их перекрёстные произведения (взаимодействия) [9-11].

Отличие от линейной модели заключается в том, что вместо прямой линии, которая может плохо проходить через облако точек, полиномиальная регрессия строит кривую, которая лучше описывает данные.

Уравнение полиномиальной регрессии степени n для одного признака:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \beta_3 x^3 + \dots + \beta_n x^n + \varepsilon,$$

где y – зависимая переменная; $\beta_0, \beta_1, \beta_2, \beta_3, \beta_n$ – коэффициенты полинома; x – независимая переменная, $x^2, x^3, \dots, x^n$ – степени признака x , ε – ошибка модели, n – степень полинома.

Если признаков несколько, то помимо степеней каждого признака, добавляют их перекрёстные произведения, вплоть до суммарной степени n .

Но сам метод регрессии не меняется, а преобразуются входные данные. Вместо одного признака x создают набор признаков: $x^2, x^3, \dots, x^n$. **Затем обучают обычную линейную регрессию** на этом новом, расширенном наборе признаков. Модель ищет оптимальные коэффициенты для этой «линейной» комбинации исходного признака и его степеней.

С использованием линейной регрессии были проанализированы исторические данные и на ее основе рассчитана математическая модель прогнозирования технологических параметров, например глубина проникания иглы, температуры размягчения и изменения температуры размягчения после старения. Расчеты по ранее сформированной математической модели (рисунок 1-4), которая была выведена благодаря регрессионному анализу данных в веб-приложении, можно реализовать на языке программирования JavaScript.

```
function handleCalculateGraphk() {

    if(!document.getElementById('fg').value){
        showModal('Необходимо ввести параметры!');
        return;
    }
    // Получаем значения из текстовых полей
    Fg = parseFloat(document.getElementById('fg').value) || 0;
    const Fb = parseFloat(document.getElementById('fb1k').value) || 0;
    const Tkishb = parseFloat(document.getElementById('tkishb').value) || 0;
    const Vus = parseFloat(document.getElementById('vus').value) || 0;
    const Tvsp = parseFloat(document.getElementById('tvspk').value) || 0;
    const Tkishg = parseFloat(document.getElementById('tkishg').value) || 0;
    const Pb = parseFloat(document.getElementById('pb').value) || 0;
    const Dtb = parseFloat(document.getElementById('dtb').value) || 0;
```

Рис. 1. Программный код реализации расчета технологических параметров

Fig. 1. Program code of the implementation of the calculation of technological parameters

Технологический параметр глубины проникания иглы, математическая модель которого основана на методе линейной регрессии, была составлена следующим образом:

```
P = 35.31 + 0.16244 * Fg - 0.06422 * Fb + 0.0856 * Tkishb - 0.01949 * Vus + 0.02112 * Tvsp + 0.10282 * Tkishg;  
document.getElementById('pResult').innerText = `Глубина проникания иглы при 25°C, 0.1мм: ${P.toFixed(2)}`;
```

Рис. 2. Ввод формулы математической модели для расчета глубины проникания иглы

Fig. 2. Entering the formula of the mathematical model for calculating the depth of needle penetration

где P – предсказываемая переменная; 35.31 – свободный член; 0.16244, 0.06422, 0.01949, 0.02112, 0.10282 – коэффициенты регрессии; $F_g, F_b, T_{кишб}, V, T_{вс}, T_{кишг}$ – независимые переменные (единицы измерения).

Технологический параметр температуры размягчения была составлена следующим образом:

```
Tkish = 36.62908 - 0.86752 * Fg + 0.387955 * Fb + 0.82036 * Tkishb + 0.49064 * Pb - 0.09777 * Tvsp;  
document.getElementById('pbResult').innerText = `Температура размягчения по кольцу и шару, °C: ${Tkish.toFixed(2)}`;
```

Рис. 3. Ввод формулы математической модели для расчета температуры размягчения

Fig. 3. Entering the formula of the mathematical model for calculating the softening temperature

где $T_{киш}$ – предсказываемая переменная; 36.62908 – свободный член; 0.86752, 0.387955, 0.82036, 0.49064, 0.09777 – коэффициенты регрессии; $F_g, F_b, T_{кишб}, P_b, T_{vsp}$ – независимые переменные

Технологический параметр изменения температуры размягчения после старения была составлена следующим образом:

```
Dt = 0.684070 + 0.076533 * Tkishb + 0.018672 * Pb + 0.123521 * Dtb;  
document.getElementById('dtResult').innerText = `Изменение температуры размягчения после старения, °C: ${Dt.toFixed(2)}`;
```

Рис. 4. Ввод формулы математической модели для расчета температуры размягчения

Fig. 4. Entering the formula of the mathematical model for calculating the change in softening temperature after aging

где DT – предсказываемая переменная; 0.684070 – свободный член; 0.684070, 0.076533, 0.018672, 0.123521 – коэффициенты регрессии; $T_{кишб}, P_b, DT_b$ – независимые переменные.

Фронтенд-часть, отвечающая за пользовательский интерфейс, может быть построена на стандартных и современных технологиях HTML5, CSS3 и JavaScript [12]. Важным преимуществом разработки клиентской части на JavaScript является возможность свободной интеграции специализированных библиотек для визуализации данных. Примером таких библиотек служит Chart.js, которая предоставляет готовые или настраиваемые типы диаграмм, такие как линейные графики, столбчатые и круговые диаграммы [13]. Эта библиотека легко подключается к проекту и позволяет в реальном времени отображать динамику технологических параметров, тренды и результаты прогнозного моделирования, обеспечивая технологический персонал интуитивно понятным и информативным инструментом для анализа. Принцип подключения таких библиотек является универсальным и полностью переносимым на РЕД ОС, что открывает доступ к большой экосистеме JavaScript без каких-либо ограничений, связанных с операционной системой [14].

После проведения расчетов, их спрогнозированные показатели будут внесены в пользовательский интерфейс, а также после расчета параметров будут показаны графики (рисунок 5-7), которые с помощью внедрения библиотеки строятся на основе математической модели.

```
function plotPressureGraph(Fg, Fb, Tkishb, Vus, Tvsp, Tkishg) {
  const ctx = document.getElementById('pChart').getContext('2d');
  const data = {
    labels: [],
    datasets: [{
      label: 'График зависимости пенетрации от расхода битума',
      data: [],
      borderColor: 'rgba(75, 192, 192, 1)',
      borderWidth: 2,
      fill: false
    }]
  };

  for (let fbValue = 0; fbValue ≤ 100; fbValue += 10) {
    const P = 35.31 + 0.16244 * Fg - 0.06422 * fbValue + 0.0856 * Tkishb - 0.01949
    * Vus + 0.02112 * Tvsp + 0.10282 * Tkishg;
    data.labels.push(fbValue);
    data.datasets[0].data.push(P);
  }

  new Chart(ctx, {
    type: 'line',
    data: data,
    options: {
      scales: {
        x: {
          title: {
            display: true,
            text: 'Расход битума (т/ч)'
          },
        },
        y: {
          title: {
            display: true,
            text: 'Пенетрация (0.1 мм)'
          },
        },
      },
    },
  });
}
```

Рис. 5. Программный код графика зависимости параметра глубины проникания иглы от расхода битума

Fig. 5. Program code for the graph of the dependence of the needle penetration depth parameter on the bitumen consumption

```
function plotTkishGraph(Fg, Fb, Tkishb, Pb, Tvsp) {
  const ctx = document.getElementById('pbChart').getContext('2d');
  const data = {
    labels: [],
    datasets: [{
      label: 'График зависимости температуры размягчения от расхода гудрона',
      data: [],
      borderColor: 'rgba(255, 99, 132, 1)',
      borderWidth: 2,
      fill: false
    }]
  };

  for (let fgValue = 0; fgValue ≤ 100; fgValue += 10) {
    const Tkish = 36.62908 - 0.86752 * fgValue + 0.387955 * Fb + 0.82036 *
    Tkishb + 0.49064 * Pb - 0.09777 * Tvsp;
    data.labels.push(fgValue);
    data.datasets[0].data.push(Tkish);
  }

  new Chart(ctx, {
    type: 'line',
    data: data,
    options: {
      scales: {
        x: {
          title: {
            display: true,
            text: 'Расход гудрона (т/ч)'
          },
        },
        y: {
          title: {
            display: true,
            text: 'Температура размягчения (°C)'
          },
        },
      },
    },
  });
}
```

Рис. 6. Программный код графика зависимости параметра температуры размягчения битума от расхода гудрона

Fig. 6. Program code for the graph of the dependence of the bitumen softening temperature parameter on the tar consumption

```
function plotDtGraph(Tkishb, Pb, Dtb) {
  const ctx = document.getElementById('dtChart').getContext('2d');
  const data = {
    labels: [],
    datasets: [{
      label: 'График зависимости изменения температуры размягчения после старения от температуры размягчения битума',
      data: [],
      borderColor: 'rgba(255, 286, 86, 1)',
      borderWidth: 2,
      fill: false
    }]
  };

  for (let tkishbValue = 38; tkishbValue ≤ 58; tkishbValue += 1) {
    const Dt = 0.684878 + 0.076533 * tkishbValue + 0.018672 * Pb + 0.123521 * Dtb;
    data.labels.push(tkishbValue);
    data.datasets[0].data.push(Dt);
  }

  new Chart(ctx, {
    type: 'line',
    data: data,
    options: {
      scales: {
        x: {
          title: {
            display: true,
            text: 'Температура размягчения битума (°C)'
          }
        },
        y: {
          title: {
            display: true,
            text: 'Изменение температуры размягчения (°C)'
          }
        }
      }
    }
  });
}
```

Рис. 7. Программный код графика зависимости параметра изменения температуры размягчения после старения от температуры размягчения битума

Fig. 7. Program code for the graph of the dependence of the softening temperature change parameter after aging on the softening temperature of bitumen

Архитектура программного обеспечения для прогнозирования характеристик технологического сырья и параметров производственных процессов строится по двухуровневому принципу, обеспечивающему надежность, масштабируемость и безопасность системы [15-17]. В основе архитектуры лежит классическая клиент-серверная модель, которая включает в себя уровень представления (клиентская часть) и уровень данных (серверная часть), разделенные по функциональному признаку. Как сказано ранее, пользовательский уровень представления реализован в виде веб-интерфейса, доступного через стандартные браузеры (рисунок 8). Этот интерфейс построен с использованием современных технологий HTML5, CSS3 и JavaScript, что обеспечивает кроссплатформенную совместимость и адаптивность под различные устройства.

Что касается серверной части и управления данными, то здесь особая роль отводится использованию системы управления базами данных PostgreSQL [7]. Ее выбор в проектах для РЕД ОС является крайне предпочтительным в контексте импортозамещения по нескольким причинам. PostgreSQL является мощной, объектно-реляционной СУБД с открытым исходным кодом [18].




Рис. 8. Архитектура программного обеспечения

Fig. 8. Software Architecture

Для запуска программного обеспечения необходимо запустить локальный сервер «server.js» [19] с помощью ввода команды в терминале (рисунок 10). Для этого в терминале необходимо войти в корневую папку проекта (рисунок 9).

```
[sa@localhost ~]$ cd /home/sa/mywebapp
```

Рис. 9. Команда для входа в корневую папку

Fig. 9. Command for entering the root folder

```
[sa@localhost mywebapp]$ node server.js
Сервер запущен на http://localhost:3000
```

Рис. 10. Команда для запуска локального сервера

Fig. 10. Command to start the local server

Для функционирования и отображения графиков необходимо подключить библиотеку Chart.js в серверной части кода программного обеспечения [20]. Серверная часть кода служит отправной точкой для запуска программного обеспечения. Далее представлена часть кода серверного приложения Server.js:

```

const express = require('express');
const { Pool } = require('pg');
const cors = require('cors');
const path = require('path');
const bodyParser = require('body-parser');

const app = express();
const port = 3000;
app.use(cors());
app.use(bodyParser.json());
app.use(express.static(path.join(__dirname))); // Это будет обслуживать все файлы в корне проекта
app.use('/js', express.static(path.join(__dirname, 'node_modules/chart.js/dist')));

```

ЗАКЛЮЧЕНИЕ

В рамках данной статьи была обоснована актуальность и представлена архитектура программного обеспечения, разработанного для прогнозирования характеристик технологических параметров. Разработанное программное обеспечение построено на основе отечественной операционной системы РЕД ОС с использованием современных веб-технологий, что обеспечивает его соответствие требованиям технологического суверенитета и промышленных стандартов. Этапом дальнейшего развития системы является разработка комплексной программы и методики испытаний (ПМИ), которая позволит провести всестороннюю проверку программного обеспечения в условиях, максимально приближенных к промышленной эксплуатации. Программа испытаний будет включать тестирование функциональности всех модулей системы, проверку устойчивости работы при длительных непрерывных нагрузках и оценку точности прогнозных моделей на производственных данных.

Методика испытаний предусматривает проведение сравнительного анализа результатов прогнозирования с фактическими производственными показателями, что позволит количественно оценить погрешность прогнозных моделей и определить направления их дальнейшей оптимизации.

Список литературы

1. Пожары и пожарная безопасность в 2019 году: статистический сборник / под общ. ред. Д.М. Гордиенко. – Москва: ВНИИПО, 2020. – 80 с.
2. Ударцева О.В. Анализ условий и причин возникновения аварийных ситуаций на нефтегазовых предприятиях // Проблемы управления рисками в техносфере. – 2020. – № 2(54). – С. 6-15. – EDN FMPLMZ.
3. Леонова И.В. Основные причины возникновения аварийных ситуаций на опасных производственных объектах // Студенческий. – 2022. – № 22-4(192). – С. 29–36.
4. Федеральный закон от 08.08.2024 № 318-ФЗ "О внесении изменений в отдельные законодательные акты Российской Федерации и признании утратившими силу отдельных положений законодательных актов Российской Федерации" // Официальный интернет-портал правовой информации. – URL: <http://www.pravo.gov.ru> (дата обращения: 15.10.2025).
5. Tanaka H., Uejima S., Asai K. Linear regression analysis with fuzzy model // IEEE Transactions on Systems, Man, and Cybernetics. – 1982. – Vol. 12, no. 6. – P. 903-907.
6. Yang Q., Liu Y., Chen T., Tong Y. Federated machine learning: Concept and applications // ACM Transactions on Intelligent Systems and Technology (TIST). – 2019. – Vol. 10, No. 2. – P. 1-19.
7. Таскин А.С. Линейная регрессия с кластеризацией по признаку на данных с действительными величинами / А.С. Таскин, Е.М. Миркес // Вестник Сибирского государственного аэрокосмического университета им. академика М.Ф. Решетнева. – 2012. – № 3(43). – С. 71-76. – EDN PCTYLN.
8. Geron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. – O'Reilly Media, 2022. – 880 p.
9. Базилевский М.П., Караулова А.В. Оценка степени нелинейности полиномиальных регрессионных моделей // Информационные технологии и математическое моделирование в управлении сложными системами. – 2022. – № 3(15). – С. 1-6. – EDN QOAUOW.
10. Петров А.В. Индикаторы первого уровня в полиномиальном регрессионном анализе / А.В. Петров // Вестник Иркутского государственного технического университета. – 2018. – Т. 22, № 5 (136).
11. Montgomery D.C., Peck E.A., Vining G.G. Introduction to linear regression analysis. – John Wiley & Sons, 2021. – 608 p.
12. Куваев М.Ю., Антимонов О.В. Современные тенденции развития веб-разработки // StudNet. – 2020. – № 9. – URL: <https://cyberleninka.ru/article/n/sovremennyye-tendentsii-razvitiya-veb-razrabotki> (дата обращения: 17.10.2025).
13. Гридин В.Н., Анисимов В.И., Васильев С.А. Методы повышения производительности современных веб-приложений // Известия ЮФУ. Технические науки. – 2020. – № 2 (212). – С. 193-200.
14. Introduction to npm // Node.js: [Электронный ресурс]. – URL: <https://nodejs.org/en/learn/getting-started/an-introduction-to-the-npm-package-manager> (дата обращения: 17.10.2025).
15. Шнайдерман Б. Проектирование пользовательского интерфейса. – Москва: ДМК Пресс, 2020. – 648 с.

16. Гайнанова Р.Ш., Широкова О.А. Создание клиент-серверных приложений // Вестник Технологического университета. – 2017. – Т. 20, № 9. – С. 79-84.
17. Полуэктова Н. Р. Разработка веб-приложений. – Москва: Юрайт, 2024. – 205 с.
18. Официальный сайт РЕД ОС: База знаний // РЕД Софт: [Электронный ресурс]. – URL: <https://redos.red-soft.ru/base> (дата обращения: 18.10.2025).
19. Свидетельство о государственной регистрации программы для ЭВМ № 2025612664 Российская Федерация. Программа автоматизированного рабочего места оператора битумной установки: заявл. 10.01.2025: опубл. 03.02.2025 / Т.М. Левина, Н.М. Чудаков, Н.С. Клинов; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Уфимский государственный нефтяной технический университет». – EDN ODTXFK.
20. Свидетельство о государственной регистрации программы для ЭВМ № 2025612821 Российская Федерация. Программа автоматизированного рабочего места технолога битумной установки: заявл. 10.01.2025: опубл. 04.02.2025 / Т.М. Левина, Н.М. Чудаков, Н.С. Клинов; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Уфимский государственный нефтяной технический университет». – EDN ADHVFT.

References

1. Fires and Fire Safety in 2019: Statistical Digest / edited by D.M. Gordienko. Moscow: VNIPO, 2020, – 80 p.
2. Udartseva O.V. Analysis of the Conditions and Causes of Emergencies at Oil and Gas Enterprises // Problems of Risk Management in the Technosphere. 2020, No. 2(54), pp. 6-15. EDN FMPLMZ.
3. Leonova I.V. The Main Causes of Emergencies at Hazardous Industrial Facilities // Student Journal, 2022, No. 22-4 (192), pp. 29–36.
4. Federal Law of 08.08.2024 No. 318-FZ "On Amendments to Certain Legislative Acts of the Russian Federation and the Repeal of Certain Provisions of Legislative Acts of the Russian Federation" // Official Internet Portal of Legal Information. – URL: <http://www.pravo.gov.ru> (date of access: 15.10.2025).
5. Tanaka H., Uejima S., Asai K. Linear regression analysis with fuzzy model // IEEE Transactions on Systems, Man, and Cybernetics. – 1982. – Vol. 12, no. 6. – P. 903-907.
6. Yang Q., Liu Y., Chen T., Tong Y. Federated machine learning: Concept and applications // ACM Transactions on Intelligent Systems and Technology (TIST). – 2019. – Vol. 10, no. 2. – P. 1-19.
7. Taskin A.S. Linear regression with feature clustering on real-valued data / A.S. Taskin, E.M. Mirkes // Bulletin of the Siberian State Aerospace University named after Academician M.F. Reshetnev. – 2012. – No. 3(43). – P. 71-76. – EDN PCTYLN.
8. Geron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. – O'Reilly Media, 2022. – 880 p.
9. Bazilevsky M.P., Karaulova A.V. Estimating the degree of nonlinearity of polynomial regression models // Information technologies and mathematical modeling in the management of complex systems. – 2022. – No. 3(15). – P. 1-6. – EDN QOAUOW.
10. Petrov AV First-level indicators in polynomial regression analysis / AV Petrov // Bulletin of Irkutsk State Technical University. – 2018. – Vol. 22, No. 5(136).
11. Montgomery D.C., Peck E.A., Vining G.G. Introduction to linear regression analysis. – John Wiley & Sons, 2021. – 608 p.
12. Kuvaev M.Yu., Antimonov O.V. Modern trends in the development of web development // StudNet. – 2020. – No. 9. – URL: <https://cyberleninka.ru/article/n/sovremennye-tendentsii-razvitiya-veb-razrabotki> (date of access: 17.10.2025).
13. Gridin V.N., Anisimov V.I., Vasiliev S.A. Methods for improving the performance of modern web applications // Bulletin of SFedU. Technical sciences. – 2020. – No. 2 (212). – P. 193-200.
14. Introduction to npm // Node.js: [Electronic resource]. – URL: <https://nodejs.org/en/learn/getting-started/an-introduction-to-the-npm-package-manager> (date of access: 17.10.2025).
15. Shneiderman B. User Interface Design. – Moscow: DMK Press, 2020. – 648 p.
16. Gainanova R.Sh., Shirokova O.A. Creating Client-Server Applications // Bulletin of the Technological University. – 2017. – Vol. 20, No. 9. – Pp. 79-84.
17. Poluektova N.R. Web Application Development. – Moscow: Yurait, 2024. – 205 p.
18. Official website of RED OS: Knowledge Base // RED Soft. – URL: <https://redos.red-soft.ru/base> (date of access: 18.10.2025).

19. Certificate of state registration of computer program No. 2025612664 Russian Federation. Automated workstation software for a bitumen plant operator: applied 10.01.2025: published 03.02.2025 / T.M. Levina, N.M. Chudakov, N.S. Klinkov; applicant Federal State Budgetary Educational Institution of Higher Education “Ufa State Petroleum Technological University”. – EDN ODTXFK.

20. Certificate of state registration of computer program No. 2025612821 Russian Federation. Automated workstation software for a bitumen plant technologist: applied 10.01.2025: published 04.02.2025 / T.M. Levina, N.M. Chudakov, N.S. Klinkov; applicant Federal State Budgetary Educational Institution of Higher Education “Ufa State Petroleum Technological University”. – EDN ADHVFT.

Левина Татьяна Михайловна, кандидат технических наук, доцент, доцент кафедры Информационных технологий, Институт нефтепереработки и нефтехимии ФГБОУ ВО УГНТУ в г. Салавате, г. Салават, Россия

Альмухаметова Элина Ильнуровна, ассистент кафедры Информационных технологий, Институт нефтепереработки и нефтехимии ФГБОУ ВО УГНТУ в г. Салавате, г. Салават, Россия

Чудаков Никита Михайлович, магистрант кафедры Информационных технологий, Институт нефтепереработки и нефтехимии ФГБОУ ВО УГНТУ в г. Салавате, г. Салават, Россия

Levina Tatyana Mikhailovna, Candidate of Technical Sciences, Associate professor, Associate Professor of the Information Technology Department, Federal State Budgetary Educational Institution of Higher Education Ufa State Petroleum Technological University in Salavat, Salavat, Russia

Almukhametova Elina Ilnurovna, Assistant Professor of the Information Technology Department, Federal State Budgetary Educational Institution of Higher Education Ufa State Petroleum Technological University in Salavat, Salavat, Russia

Chudakov Nikita Mikhailovich, Master's Student of the Information Technology Department, Federal State Budgetary Educational Institution of Higher Education Ufa State Petroleum Technological University in Salavat, Salavat, Russia

УДК 004.75

DOI: 10.18413/2518-1092-2026-11-2-0-4

Хлопов А.М.
Сулханов И.И.

**СИСТЕМНЫЙ АНАЛИЗ АРХИТЕКТУР И МОДЕЛЬ ВЫБОРА
ДЛЯ РАСПРЕДЕЛЁННЫХ СИСТЕМ СИНХРОННОЙ
ДОСТАВКИ ПОТОКОВОГО МУЛЬТИМЕДИЙНОГО
КОНТЕНТА С КООРДИНАЦИЕЙ УПРАВЛЯЮЩИХ
СИГНАЛОВ**

Белгородский государственный технологический университет им. В.Г. Шухова,
ул. Костюкова, 46, г. Белгород, 308012, Россия

e-mail: 20044002ilya@gmail.com

Аннотация

В статье рассматривается задача системного анализа архитектур распределённых систем синхронной доставки потокового мультимедийного контента с координацией управляющих сигналов в сценариях совместного просмотра. Актуальность обусловлена тем, что пользовательский опыт определяется одновременно характеристиками медиадоставки и контура управления, а несогласованность этих контуров приводит к рассинхронизации, задержкам реакции и деградации интерактивности. Проблема заключается в сложности архитектурного выбора, при котором функциональные требования к синхронизации потоков и нефункциональные требования системы должны быть учтены до этапа выбора конкретных протоколов и реализации. Методы: применяется подход системного анализа с декомпозицией решения на медиаплоскость и плоскость управления; выделяются базовые классы архитектур по принципу организации медиадоставки (pull-based и push-based). Результаты: предложена модель выбора архитектурного класса, основанная на анализе функциональных и нефункциональных требований к синхронизации потоковых данных, дополняемая анализом рисков выбранного класса, способных привести к пересмотру требований. Выводы: результаты могут быть использованы как методологическая рамка раннего архитектурного отбора при проектировании систем синхронного VOD-просмотра и низколатентных real-time сценариев, снижая вероятность поздней смены архитектурного подхода.

Ключевые слова: синхронная доставка мультимедиа; совместный просмотр; архитектура распределённых систем; real-time системы; pull-based архитектуры; push-based архитектуры; координация управляющих сигналов; системный анализ

Для цитирования: Хлопов А.М., Сулханов И.И. Системный анализ архитектур и модель выбора для распределённых систем синхронной доставки потокового мультимедийного контента с координацией управляющих сигналов // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 36-49. DOI: 10.18413/2518-1092-2026-11-2-0-4

Khlopov A.M.
Sulkhanov I.I.

**SYSTEMIC ANALYSIS OF ARCHITECTURES
AND A SELECTION MODEL FOR DISTRIBUTED SYSTEMS
OF SYNCHRONOUS STREAMING MULTIMEDIA CONTENT
DELIVERY WITH CONTROL SIGNAL COORDINATION**

Belgorod State Technological University named after V.G. Shukhov,
46 Kostyukova St., Belgorod, 308012, Russia

e-mail: 20044002ilya@gmail.com

Abstract

The paper addresses the problem of systemic analysis of architectures for distributed systems providing synchronous delivery of streaming multimedia content with coordinated control signals

in watch-together scenarios. The relevance of the study is determined by the fact that user experience depends simultaneously on media delivery characteristics and the control plane, while inconsistency between these layers leads to desynchronization, delayed reactions, and degradation of interactivity. The problem lies in the complexity of architectural decision-making, where functional requirements for stream synchronization and non-functional system requirements must be considered prior to selecting specific protocols and implementation approaches. Methods: a systems analysis approach is applied with decomposition into media and control planes; fundamental architecture classes are identified based on the organization of media delivery (pull-based and push-based). Results: a model for selecting an architectural class is proposed, based on the analysis of functional and non-functional requirements for stream synchronization, supplemented by risk analysis of the chosen class that may necessitate requirement revision. Conclusions: the results can be used as a methodological framework for early architectural selection in the design of synchronous VOD systems and low-latency real-time scenarios, reducing the likelihood of late-stage architectural changes.

Keywords: synchronous multimedia delivery; co-watching; distributed system architecture; real-time systems; pull-based architectures; push-based architectures; control signal coordination; systems analysis

For citation: Khlopov A.M., Sulkhanov I.I. Systemic Analysis of Architectures and a Selection Model for Distributed Systems of Synchronous Streaming Multimedia Content Delivery with Control Signal Coordination // Research result. Information technologies. – T. 11, № 2, 2026. – P. 36-49. DOI: 10.18413/2518-1092-2026-11-2-0-4

ВВЕДЕНИЕ

В последние годы всё шире используются сервисы совместного просмотра видео, когда несколько пользователей, на разных устройствах, смотрят один и тот же контент и могут вместе управлять воспроизведением (пауза, перемотка, запуск и т.д.). На практике такая функциональность требует решения двух связанных задач: надёжной доставки мультимедийного потока каждому участнику и скоординированного распространения управляющих сигналов, чтобы состояние «комнаты» просмотра у всех совпадало [10, 12, 26].

Особенность подобных систем состоит в том, что медиапоток и управляющие события распространяются по разным каналам и с разными задержками. Если задержка доставки видео у пользователей отличается, то даже корректно отправленная команда (например, «пауза») может примениться на разных моментах таймлайна. В результате возникает рассинхронизация, которая может достигать значимых величин и заметно ухудшать пользовательский опыт, особенно при потоковой передаче по сегментированным HTTP-подходам, где задержки у разных зрителей могут различаться на секунды [6, 13, 14, 19, 23–25, 30].

В статье рассматривается архитектурный уровень решения данной задачи – без привязки к конкретным реализациям или протоколам. Анализ фокусируется на способах организации медиаплоскости и плоскости управления, их взаимодействии и влиянии на синхронность, задержки и масштабируемость системы. На основе системного анализа выделяются типовые классы архитектурных подходов и исследуются их характерные свойства и ограничения в контексте совместного просмотра мультимедийного контента.

ОСНОВНАЯ ЧАСТЬ

Цель работы – выполнить системный анализ архитектурных подходов к синхронной доставке мультимедийного контента с координацией управляющих сигналов и сформировать модель выбора архитектуры под конкретные требования, а также описать типовые риски архитектур. В работе вводятся критерии сравнения, выделяются базовые классы архитектурных решений и приводится их сопоставление по ключевым параметрам, после чего предлагается итоговая модель выбора.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Постановка задачи и основные понятия

В работе рассматривается задача синхронной доставки потоковых данных группе пользователей. Потоки данных и управляющие сигналы передаются по разным каналам и с разными задержками, что приводит к рассогласованию состояния. Анализируются архитектурные подходы, применяемые для решения данной задачи в распределённых системах. На основе анализа формируется модель выбора архитектуры на основании требований и рисков [1, 4, 9].

Далее вводится базовая модель предметной области и основные понятия, используемые в работе.

Комната – логическая сессия совместного просмотра, объединяющая группу пользователей, которые воспроизводят один и тот же мультимедийный контент в согласованном режиме.

Состояние комнаты – совокупность параметров, необходимых для поддержания синхронности и воспроизводимости сессии. Минимально включает:

- идентификатор/адрес воспроизводимого контента (URL, media ID, stream ID);
- текущую целевую позицию воспроизведения на таймлайне (плейхед);
- режим воспроизведения (play/pause, скорость, при наличии);
- и может включать вспомогательные данные: список участников, роли, параметры доступа, признаки актуальности состояния (версия и т.д.), метки времени и т.п.

Плейхед – логический указатель времени на таймлайне контента, задающий целевую позицию воспроизведения, которая должна быть согласована между участниками комнаты.

Управляющие события – дискретные команды, изменяющие состояние комнаты и/или требующие согласованного применения на клиентах. Типовые события: start/pause/resume, seek(t), смена контента, подключение/отключение участника, смена роли, изменение настроек воспроизведения и т.п. Источник события – пользователь (UI-действие) либо система (правила синхронизации, восстановление после сбоев, таймеры, бизнес-логика).

Рамка системного анализа архитектур

Для системного сравнения решений удобно разделить общую задачу синхронного стриминга на две плоскости: медиаплоскость и плоскость управления. Этот подход аналогичен широко применяемому разделению плоскости данных и плоскости сигнализации в телекоммуникациях [2, 3, 15]. В контексте совместного просмотра:

- Медиаплоскость охватывает всё, что связано с доставкой аудио-видеоданных от источника контента к клиентским плеерам. Сюда входит выбор протокола и способа стриминга (например, сегментированный HTTP-поток типа HLS/DASH, либо же мало-задержочный поток типа WebRTC, RTP и т.п.), организация буферизации на клиенте, использование адаптивного битрейта (ABR) для подстройки качества под канал, механизмы декодирования и вывода медиа. Медиаплоскость определяет такие параметры, как базовая задержка потока (например, HLS обычно имеет latency порядка десятков секунд, WebRTC – сотни миллисекунд), равномерность задержек у разных клиентов, устойчивость к потере пакетов, и т.д. Именно от решений в медиаплоскости зависит, насколько синхронно вообще могут получать контент разные пользователи – есть ли у них общий ориентир по времени или каждый “живёт” в своём временном лаге относительно источника [6, 13, 14, 19, 22–25, 29].

- Плоскость управления охватывает обмен служебными сообщениями и командами для обеспечения синхронности. Это логический слой, который следит, чтобы состояние комнаты оставалось согласованным. В плоскости управления решаются вопросы: как рассылаются управляющие события (от одного клиента напрямую другим или через центральный сервер сигнализации); кто и где хранит текущее эталонное состояние (например, хранят ли клиенты локально позицию плейхеда или есть центральный координатор, считающийся источником

правды); как новые участники узнают текущее состояние при присоединении; как контролируется право инициировать те или иные команды (например, все ли могут жать Play/Pause или только “хост” сессии). Также плоскость управления может включать сопутствующие функции – обмен сообщениями/чатом, реакции, однако их можно рассматривать отдельно от синхронизации воспроизведения. Главное – механизм распространения сигналов синхронизации должен быть оперативным и надёжным, будь то широковещательные UDP-пакеты, WebSocket-сообщения или peer-to-peer канал данных [10-12, 16, 17, 21, 26].

Оси классификации архитектур. Используя указанное разделение, можно классифицировать архитектурные решения по нескольким ключевым осям (параметрам):

1. Способ организации медиапотока (доставка медиа). Здесь варианты лежат в спектре от буферизированных HTTP-подходов до реалтайм-подходов. Буферизированные подходы подразумевают, что каждый клиент независимо загружает потоковое видео через сегментированные файлы (HLS, MPEG-DASH) либо прогрессивное скачивание, используя существующую CDN-инфраструктуру. Реалтайм-подходы предполагают, что поток доставляется синхронно по сути в режиме реального времени – либо через прямые peer-to-peer соединения, либо через сервер ретрансляции, с минимальной буферизацией (WebRTC, RTMP/RTSP в режиме live, multicast и пр.). Между ними возможны компромиссы, например: использование Low Latency HLS (ускоренная версия HTTP-потока с маленькими сегментами ~1 с и т.д.) или CMAF, которые сокращают задержку, но все еще опираются на HTTP; либо использование P2P-сетей для доставки сегментов. Важное различие – независимая и общая доставка: при HTTP-подходе каждый клиент получает свои копии сегментов и медиаплоскость не гарантирует единого времени у всех (без внешней синхронизации), тогда как при общем потоке (например, один WebRTC-поток на всех) все клиенты получают один и тот же кадр “одновременно”.

2. Способ организации доставки управляющих событий. Управляющие сигналы могут передаваться несколькими путями. Через центральный узел, когда все клиенты подключаются к серверу сигнализации, который принимает команды от одного участника и ретранслирует их всем остальным. Децентрализованно, peer-to-peer, когда клиенты сами обмениваются сигналами между собой напрямую. А также гибридно, например при иерархической передаче, когда сигнал от инициатора идёт «ведущему» или серверу, а от него – остальным, либо при использовании существующей структуры контента для передачи сигналов. Важно также, как часто или по какому триггеру шлются сигналы синхронизации: возможно, как только при событии, так и периодически посылать метки с текущим состоянием, чтобы корректировать рассинхронизацию.

3. Расположение “истины” состояния (кого считать источником правды). Иначе говоря, где хранится и откуда берётся эталонное значение общего времени воспроизведения, по которому все выравниваются. Возможны несколько принципиально разных подходов. (а) Централизованный эталон: выделяется сервер или сервис, который хранит текущее состояние комнаты (например, “все должны быть на позиции 5 мин 20.0 сек”) и именно он диктует остальным клиентам, где они должны находиться. Клиенты регулярно отчитываются о своём положении, а сервер при необходимости даёт команду “подтянуться” или “приостановить/ускорить” конкретным участникам, чтобы все вновь выровнялись. Такой подход часто называют server authoritative – сервер авторитарно определяет состояние. (б) Ведущий клиент (host authoritative): роль эталона играет один из клиентов, обычно создатель комнаты или первый подключившийся. Его таймлайн считается “ведущим”, а все остальные клиенты подстраиваются под него. Например, при старте все начинают воспроизведение синхронно с ведущим; если у ведущего случился буферинг и он остановился – у всех остальных система тоже приостановит видео, ожидая, пока лидер продолжит, и т.п. Достоинство – нет необходимости постоянно опрашивать всех, достаточно отслеживать лидера; недостаток – если у ведущего проблемы, они передадутся всем. (в) Распределённая или договорная “истина”: состояние выводится из объединённых данных всех клиентов. Например, можно вычислять среднее положение по всем клиентам и брать его за эталон (никто не лидер, но все стремятся к общему среднему времени). Или более тонкий вариант – взвешенное среднее с учетом типов устройств (например, мобильные могут чуть отставать, поэтому вес их позиции меньше). Ещё подход –

привязка ко внешнему времени: все клиенты синхронизируют системные часы через NTP и меткой служит реальное время. Например, если договориться, что воспроизведение должно идти так, будто начато ровно в 12:00:00 GMT, то каждый клиент может сам вычислять, где он должен быть, исходя из текущего времени. Подобный приём реализуется посредством метаданных в потоке: так, HLS может вставлять теги EXT-X-PROGRAM-DATE-TIME с меткой времени начала сегмента, и если все устройства имеют синхронные часы, то абсолютное время служит ориентиром [18, 19, 27, 28]. При распределённом подходе сложнее управление в реальном времени (например, пауза), но повышается устойчивость: отсутствие единой точки отказа и возможность компенсировать индивидуальные задержки.

Заданные выше оси позволяют описать любую конкретную реализацию. Однако цель данной работы – не анализ частных платформ, а обобщение до классов архитектурных решений. Поэтому в следующем разделе, комбинируя варианты по осям, мы выделим базовые классы подходов к синхронной доставке и рассмотрим их характеристики.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

В рамках данной работы анализ архитектурных подходов и формирование результатов не разделяются на отдельные этапы, поскольку результаты исследования представляют собой непосредственно выводы системного анализа. Поэтому в данном разделе совместно представлены полученные классификации, модель выбора архитектуры и их интерпретация в контексте рассматриваемых сценариев.

Классы архитектур синхронной доставки

С точки зрения медиаплоскости решения удобно классифицировать по тому, кто инициирует доставку медиаданных – источник (push) или клиент (pull). В рамках данной работы выделяются два базовых класса:

1. Pull-based client-driven segment streaming (HLS/DASH-класс) – клиент самостоятельно запрашивает медиасегменты и управляет буфером/адаптацией качества; синхронизация достигается преимущественно на плоскости управления и за счёт алгоритмов коррекции.

2. Push-based real-time streaming (WebRTC/RTP-класс) – после установления сессии источник/сервер передаёт медиаданные непрерывным потоковым образом; синхронность в значительной мере обеспечивается транспортом и общей временной базой.

Каждый класс далее описывается через медиаплоскость, плоскость управления и источник “истины” состояния комнаты.

Pull-based подходы (независимая сегментная доставка с координацией событий)

Суть архитектуры.

Медиаплоскость строится на сегментированной доставке: клиентский плеер получает манифест и далее сам запрашивает последовательность сегментов (HLS/DASH и аналогичные ABR-схемы), формирует буфер и воспроизводит контент локально. Плоскость управления реализуется отдельно (как правило, централизованным сервером сигнализации): передаются события *play/pause/seek* и служебные сообщения для поддержания состояния комнаты.

Ключевой момент: буфер и задержка формируются индивидуально на каждом клиенте, поэтому медиаплоскость сама по себе строгую синхронность не обеспечивает.

Как достигается синхронизация.

Синхронизация реализуется поверх сегментной доставки через:

- согласованную модель состояния комнаты (*server-authoritative* или *host-authoritative*);
- периодические маяки с текущей позицией и состоянием воспроизведения;
- корректирующие действия – *seek*, кратковременная пауза, временное изменение скорости воспроизведения;

- политику работы с буфером (пороги допустимого рассогласования и т.д.) [8, 10, 12, 26, 27].

Сильные стороны.

- Масштабируемость медиаплоскости: нагрузка на доставку контента переносится на стандартную HTTP-инфраструктуру и/или CDN.
- Невысокая сложность медиачасти: используются готовые плееры и зрелые протоколы сегментной доставки, не требуется собственный real-time медиасервер.
- Использование ABR и типовых цепочек доставки: механизмы адаптации качества и кэширования хорошо отлажены для массового просмотра.

Ограничения.

- Дрейф плеихеда из-за независимых буферов и сетевой вариативности: без активной коррекции рассинхронизация накапливается.
- Нижняя граница задержки задаётся сегментацией и размерами буфера: команда может быть доставлена быстро, но мгновенное применение ограничено уже загруженными сегментами.
- При стремлении к строгому синхрону усложняются алгоритмы коррекции (пороги, частота выравнивания), повышается риск “дёргания” воспроизведения.

Типовые области применения.

Совместный просмотр VOD-контента и сценарии, где важны масштаб и простота, а задержки порядка секунд и “практическая” синхронность в малых/средних группах приемлемы.

Push-based подходы (общий поток с минимальной задержкой)

Суть архитектуры.

Медиаплоскость строится на потоковой доставке реального времени: после установления сессии медиаданные передаются единым потоком (WebRTC/RTP-класс протоколов и аналогичные решения), буфер минимален, используются временные метки и механизмы восстановления часов [7, 16, 17, 20–22, 28, 29]. Распространение потока организуется либо как P2P-соединения для малых групп, либо через медиасервер ретрансляции (SFU/MCU) для большего числа участников.

Плоскость управления выделяется в отдельный канал (сигнализация, управление сессией, вспомогательные события), однако синхронность уже в значительной мере обеспечивается самим транспортом и общей временной базой.

Как достигается синхронизация.

Синхронность возникает естественным образом: клиенты получают данные из общего потока и воспроизводят их по общей временной базе (*timestamp, clock recovery, jitter buffer*). Управляющие события чаще выражаются в изменении состояния источника или медиасессии (старт/стоп, смена источника, переключение дорожек). Коррекция рассинхронизации сосредоточена в механизмах компенсации задержек и дрейфа часов, а не в регулярных *seek*-операциях на уровне приложения.

Сильные стороны.

- Минимальная рассинхронизация и малая задержка: разница отображения между участниками ограничена сетевой задержкой и обработкой.
- Быстрая реакция на управляющие события: отсутствует крупный индивидуальный буфер, поэтому управление воспринимается более “живым”.
- Естественная поддержка интерактивности: голос/видео-чат, реакции и совместные действия работают в едином временном контексте.

Ограничения.

- Повышенная сложность и стоимость инфраструктуры: требуется сигнальная подсистема, NAT-traversal, медиасерверы, мониторинг качества и отказоустойчивость.
- Ограничения масштабируемости: fan-out на большую аудиторию требует существенных ресурсов и обычно дороже по сравнению с CDN-доставкой.
- Чувствительность к качеству сети: при малом буфере проблемы сети быстро проявляются фризами, падением качества или ростом задержки.

Типовые области применения.

Совместный просмотр live-контента, интерактивные форматы и обучающие сессии, где критичны минимальная задержка и строгая синхронность, а также малые группы, где real-time стек оправдан.

О гибридных подходах и границах применимости понятия

Интуитивно может показаться, что между pull-based и push-based медиадоставкой существует “гибридный” класс. Однако такое определение некорректно: pull-based и push-based подходы различаются не настройками, а самим механизмом передачи (кто инициирует доставку и как формируется буфер). Поэтому “гибрид” в смысле *смешения протоколов медиадоставки* внутри одной и той же медиаплоскости обычно не образует самостоятельного, устойчивого архитектурного класса.

Тем не менее, термин “гибрид” допустимо использовать в двух более строгих смыслах.

1) Гибрид как сближение свойств при неизменном механизме доставки.

На практике встречаются решения, в которых одна архитектура стремится по свойствам к другой:

- сегментная pull-based доставка может приближаться к real-time по задержке за счёт низколатентных режимов, уменьшения сегментов/чанков, ускоренного обновления плейлиста и усиления контуров синхронизации (частые маяки, более строгие политики коррекции, опора на временные метки и синхронизацию часов) [6, 13, 19, 23, 24, 28, 30];

- push-based real-time стек может частично “заимствовать” свойства массовой доставки (например, через каскадирование ретрансляции, многорегиональную инфраструктуру, адаптацию качества), но остаётся push-based по механике передачи.

В обоих случаях архитектура по-прежнему принадлежит исходному классу (pull-based или push-based), а “гибридность” относится лишь к приближению эксплуатационных свойств (задержка, устойчивость, точность синхронизации, стоимость).

2) Гибрид как композиция на уровне системы.

Понятие гибрида применимо на уровне системы, когда разные фичи реализованы разными архитектурами. Например, сервис может обеспечивать:

- совместный просмотр VOD-контента на pull-based сегментной доставке (HLS/DASH- класс),
- и одновременно двустороннюю голосовую/видео-связь участников на push-based real-time доставке (WebRTC/RTP-класс).

В таком случае система является гибридной по архитектуре в целом, но каждая конкретная функциональность внутри неё реализована одним из базовых классов медиадоставки.

Теперь, определив два базовых класса решений для медиаплоскости и уточнив границы употребления термина «гибрид» и то, почему в данной работе он не рассматривается как самодостаточный класс архитектуры, сведём различия подходов более формально и рассмотрим потенциальные проблемы (риски), возникающие при их реализации.

Модель выбора архитектуры и применение

На основании проведённого системного анализа архитектур синхронной доставки потокового мультимедийного контента предлагается модель выбора архитектуры, ориентированная на уровень системы и групп функциональностей, а не на отдельные протоколы или инженерные реализации. Цель модели заключается не в количественной оптимизации параметров и не в детальном проектировании, а в выявлении архитектурно корректного способа организации доставки потоковых данных и управляющих сигналов с учётом как функциональных, так и нефункциональных требований.

Модель исходит из того, что архитектурные ограничения во многих случаях задаются функциональными требованиями системы и лишь затем уточняются через требования к задержкам (синхронности) и масштабируемости.

Ограниченность однокритериального и чисто нефункционального подходов

Если рассматривать выбор архитектуры только через призму качества пользовательского опыта, выраженного минимальной задержкой и строгой синхронностью воспроизведения, модель выбора становится вырожденной: во всех случаях предпочтение будет отдаваться push-based архитектурам, обеспечивающим доставку данных в реальном времени на основе общей временной базы.

Однако подобный подход неприменим в системах промышленного масштаба. Он игнорирует ограничения, связанные с нагрузкой, масштабируемостью и эксплуатационными затратами, и не позволяет объяснить, почему в реальных системах совместного просмотра широко применяются pull-based решения [3, 5, 9, 15].

Введение второго нефункционального критерия – масштабируемости (capacity), понимаемой как способность системы обслуживать растущее число пользователей и сессий при допустимом уровне задержек, устраняет вырожденность модели. Тем не менее, даже двухкритериальная модель, основанная исключительно на нефункциональных требованиях, остаётся недостаточной. Она не объясняет ситуации, в которых выбор архитектуры фактически предопределён функциональными ограничениями и не может быть разрешён компромиссом между задержкой и нагрузкой.

Роль функциональных требований и группировка функциональностей

Предлагаемая модель исходит из того, что первичным шагом архитектурного выбора является анализ функциональных требований системы, а именно – выявление функциональностей, порождающих потоковые данные, и характера их взаимной синхронизации.

Ключевой вопрос модели формулируется следующим образом: существуют ли в системе две или более функциональности, порождающие независимые потоковые данные, которые по функциональным требованиям должны быть взаимно синхронизированы?

Под независимыми потоковыми данными понимаются аудио-, видео- или иные непрерывные потоки, формируемые различными участниками или компонентами системы и не являющиеся производными друг от друга. Примерами таких функциональностей могут служить голосовое общение нескольких участников, совместная демонстрация экрана и видеопоток, либо одновременная передача нескольких медиапотоков в рамках одного взаимодействия.

Если такие функциональности присутствуют и между ними требуется строгая синхронизация, модель утверждает, что они должны быть объединены в единую группу и реализованы в рамках push-based архитектуры. В данном случае выбор архитектурного класса определяется функционально и не является предметом оптимизации: использование pull-based подходов либо технически не позволяет обеспечить требуемую синхронность, либо приводит к неустойчивой системе при фиксированных ресурсах.

Таким образом, наличие группы функциональностей, порождающих независимые потоки, требующие синхронизации, является достаточным условием для выбора push-based архитектуры для данной части системы.

Архитектурный выбор для оставшихся функциональностей

Функциональности, не входящие в указанные группы, то есть не порождающие независимые потоковые данные, требующие взаимной синхронизации, не накладывают жёстких архитектурных ограничений. Для них архитектурный выбор осуществляется на основе нефункциональных требований, прежде всего требований к задержке, допустимой рассинхронизации и масштабируемости.

В таких случаях модель допускает использование pull-based архитектур как предпочтительного варианта с точки зрения масштабируемости и эксплуатационной простоты. Для этих функциональностей push-based подход может использоваться, но в основном определяется особенностями реализации, чем требованиями к синхронности.

Функциональности, не имеющие особых требований к синхронности, могут работать как в отдельных архитектурных контурах, так и поверх существующей push-based инфраструктуры.

Обобщённая формулировка модели

Предлагаемая модель сводится к следующим положениям:

1. Архитектурный выбор выполняется на более абстрактном уровне, чем уровень отдельных компонентов или протоколов, а именно на уровне групп функциональностей.
2. Если группа функциональностей порождает два и более независимых потока данных, которые должны синхронизироваться между собой, для неё рекомендован выбор push-based подхода.
3. Для функциональностей, не подпадающих под данное ограничение, архитектурный выбор определяется нефункциональными требованиями и сводится к компромиссу между синхронностью и масштабируемостью.
4. Попытка реализовать функционально обусловленные сценарии синхронизации в pull-based архитектуре при фиксированных ресурсах приводит к снижению масштабируемости без достижения требуемого качества синхронного взаимодействия.
5. Модель не заменяет инженерное проектирование, а задаёт архитектурную рамку, внутри которой выполняется дальнейший анализ рисков и затрат.

Роль модели в процессе проектирования

Предлагаемая модель применяется на ранних этапах проектирования системы. Сначала анализируются функциональные требования и формируются группы функциональностей, требующие потоковой синхронизации. Для таких групп архитектурный выбор фиксируется. Далее для остальных частей системы анализируются нефункциональные требования и выбираются архитектурные решения, оптимальные с точки зрения масштабируемости и эксплуатационных ограничений.

В случае выявления противоречий между требованиями к синхронности и доступными ресурсами модель предполагает не усложнение архитектуры за счёт неустойчивых инженерных компромиссов, а пересмотр требований и сценариев использования. Таким образом, модель служит инструментом архитектурной валидации требований и позволяет избежать проектных решений, заведомо приводящих к деградации системы по мере её развития.

Архитектурные риски и основания для пересмотра требований

Предложенная модель выбора архитектуры позволяет определить архитектурный класс, соответствующий совокупности функциональных и нефункциональных требований к системе синхронной доставки потокового мультимедийного контента. Однако даже корректное применение модели не устраняет архитектурные риски. Напротив, анализ рисков является неотъемлемой частью процесса выбора, поскольку именно на этом этапе выявляются внутренние противоречия требований и ограничения, неочевидные на стадии их формулирования.

В данном разделе рассматриваются архитектурные риски не как частные технические проблемы реализации, а как фундаментальные ограничения, способные привести к невозможности выполнения исходных требований и, как следствие, к необходимости их пересмотра.

Риски для функциональностей, требующих взаимной синхронизации потоков

Функциональности, порождающие два и более независимых по происхождению потоков данных, которые должны быть синхронизированы относительно друг друга (например, голос и видео участников, совместное воспроизведение с живыми комментариями, интерактивные медиасценарии), накладывают жёсткие архитектурные ограничения. Для этих функциональностей модель рекомендует использовать push-based архитектуру, так как другие подходы не дают стабильно обеспечивать требуемый уровень синхронности.

Риски при выборе push-based архитектуры

Основным недостатком push-based архитектур являются высокие требования к инфраструктуре и сложности масштабирования. Поддержка синхронного взаимодействия пользователей требует постоянных соединений, обработки медиапотоков в реальном времени и участия медиасерверов, из-за чего при увеличении числа пользователей возрастает нагрузка на вычислительные и сетевые ресурсы [5, 9, 20, 29].

На практике это может приводить к необходимости ограничения числа участников, снижения требований к синхронности или разделения сценариев использования. Дополнительным недостатком является чувствительность таких архитектур к нестабильности сети и отказам медиасерверов, которые могут одновременно затрагивать всех участников взаимодействия.

Следовательно, основной риск push-based архитектур связан с ограниченностью доступных инфраструктурных ресурсов при высоких требованиях к синхронности взаимодействия.

Риски при выборе pull-based архитектуры вопреки требованиям

Выбор pull-based архитектуры для функциональностей, требующих строгой синхронизации потоков, ограничивает минимально достижимую задержку и точность синхронизации из-за буферизованной доставки и клиентского управления загрузкой сегментов.

Попытки компенсировать эти ограничения за счёт усложнения плоскости управления (частые корректирующие команды, ускорения, паузы, частая синхронизация плейхедов) приводят к росту нагрузки, снижению предсказуемости поведения системы и ухудшению пользовательского опыта. При фиксированных ресурсах улучшение синхронности неизбежно сопровождается падением масштабируемости, что делает систему неустойчивой при росте нагрузки.

Риски для функциональностей, не требующих взаимной синхронизации потоков

Функциональности, порождающие потоковые данные, но не требующие строгой синхронизации с другими независимыми потоками, не накладывают жёстких архитектурных ограничений. Для этого класса функциональностей модель не формирует директивной рекомендации по выбору архитектурного класса. Архитектурный выбор в данном случае осуществляется исключительно на основе нефункциональных требований и компромисса между задержкой и масштабируемостью.

Отсутствие жёсткой рекомендации не устраняет риски, а, напротив, переносит ответственность за архитектурное решение на этап интерпретации требований.

Риски при смещении выбора в сторону push-based архитектуры

Выбор push-based архитектуры для функциональностей, не требующих взаимной синхронизации потоков, связан с риском избыточной сложности. Архитектура накладывает ограничения по масштабируемости и требует значительных ресурсов на поддержку real-time соединений, не предоставляя при этом функционального выигрыша, критичного для пользовательского опыта.

В таких случаях риск заключается в том, что архитектурные ограничения оказываются искусственно навязанными системе. Это может привести к преждевременному росту затрат, усложнению эксплуатации и снижению устойчивости системы без объективной необходимости. При изменении требований или росте нагрузки возникает потребность пересмотра архитектуры, несмотря на то что функциональные требования изначально этого не требовали.

Риски при смещении выбора в сторону pull-based архитектуры

Выбор pull-based архитектуры для данного класса функциональностей, как правило, соответствует текущим требованиям. Однако архитектурный риск возникает в случае недооценки возможной эволюции сценариев использования. Постепенное увеличение интерактивности, появление новых потоковых функциональностей или рост ожиданий пользователей могут привести к ситуации, в которой исходные допущения о допустимой задержке и рассинхронизации перестают быть актуальными.

В этом случае риск заключается не в технической невозможности реализации, а в архитектурной инерции: система оказывается привязана к подходу, плохо адаптируемому к новым требованиям. Выявление такого риска требует либо раннего закладывания механизмов расширения, либо готовности к пересмотру архитектурного класса в будущем.

Риски как инструмент уточнения требований

Рассмотренные риски показывают, что архитектурный выбор не может рассматриваться изолированно от требований к системе. В ряде случаев именно анализ архитектурных рисков позволяет выявить внутреннюю противоречивость требований, избыточность ограничений или неверную оценку будущего развития функциональностей.

В рамках предложенной модели риски рассматриваются не как сбои, подлежащие устранению исключительно инженерными средствами, а как сигналы необходимости пересмотра требований. Такой подход предполагает итеративный процесс: после выбора архитектурного класса и анализа характерных рисков принимается решение либо о переходе к детальному проектированию, либо об уточнении и корректировке исходной постановки задачи.

Это позволяет избежать архитектурных решений, которые формально удовлетворяют требованиям на начальном этапе, но оказываются неустойчивыми по мере развития системы и роста нагрузки.

ЗАКЛЮЧЕНИЕ

В данной работе выполнен системный анализ архитектурных подходов к построению распределённых систем синхронной доставки потокового контента с координацией управляющих сигналов. Рассмотрены базовые архитектурные классы, различающиеся способом организации медиадоставки и управления состоянием совместного просмотра, а также выявлены их фундаментальные свойства и ограничения. В процессе работы было установлено, что выбор архитектуры для систем синхронного взаимодействия определяется не отдельными протоколами или технологиями, а требованиями к синхронности, задержкам и масштабируемости системы. Между архитектурными подходами существует прямой компромисс: повышение точности синхронизации обычно приводит к росту нагрузки на инфраструктуру и снижению масштабируемости.

На основе проведённого анализа была сформулирована модель выбора архитектуры, ориентированная на сопоставление требований сценария с архитектурным классом системы. Дополнительные параметры при этом рассматриваются как ограничения и риски, учитываемые после выбора базового архитектурного подхода.

Предложенная модель может использоваться при формировании требований к системам синхронного взаимодействия и на ранних этапах проектирования распределённых интерактивных систем.

Список литературы

1. Волкова В.Н., Денисов А.А. Теория систем и системный анализ: учебник для вузов. 3-е изд. М.: Юрайт, 2021. 562 с. URL: <https://urait.ru/bcode/488173> (дата обращения: 12.01.2026).
2. ГОСТ Р 57100-2025. Системная и программная инженерия. Описание архитектуры. 2025. URL: <https://docs.cntd.ru/document/1312121066> (дата обращения: 18.12.2025).
3. ГОСТ Р ИСО/МЭК 25010-2015. Информационные технологии. Системная и программная инженерия. Требования и оценка качества систем и программного обеспечения (SQuaRE). Модели качества систем и программных продуктов. 2015. URL: <https://docs.cntd.ru/document/1200121069> (дата обращения: 09.01.2026).
4. Козлов В.Н. Системный анализ, оптимизация и принятие решений: учебное пособие. СПб.: Изд-во Политехн. ун-та, 2011. 244 с. URL: <https://elibrary.spbstu.ru/dl/2/2887.pdf> (дата обращения: 21.12.2025).
5. Митра Р., Надареишвили И. Микросервисы. От архитектуры до релиза. СПб.: Питер, 2023. 336 с.
6. Apple Inc. Low-Latency HLS. URL: https://developer.apple.com/documentation/http_live_streaming/using_low-latency_http_live_streaming (дата обращения: 14.01.2026).
7. Baugher M., McGrew D., Naslund M., Carrara E., Norrman K. The Secure Real-time Transport Protocol (SRTP). RFC 3711. 2004. URL: <https://www.rfc-editor.org/rfc/rfc3711.html> (дата обращения: 27.12.2025).
8. Boronat F., Lloret J., García M. Multimedia group and inter-stream synchronization techniques: a comparative study // Information Systems. 2009. Vol. 34, No. 1. P. 108–131. DOI: 10.1016/j.is.2008.05.001.
9. Clements P., Kazman R., Klein M. Evaluating Software Architectures: Methods and Case Studies. Boston: Addison-Wesley, 2001. 300 p.
10. ETSI TS 103 286-2 V1.1.1. Digital Video Broadcasting (DVB); Companion Screens and Streams; Part 2: Content Identification and Media Synchronization. 2017. URL: https://www.etsi.org/deliver/etsi_ts/103200_103299/10328602/01.01.01_60/ts_10328602v010101p.pdf (дата обращения: 03.01.2026).
11. Fette I., Melnikov A. The WebSocket Protocol. RFC 6455. 2011. URL: <https://www.rfc-editor.org/rfc/rfc6455.html> (дата обращения: 19.12.2025).
12. Geerts D., Vaishnavi I., Mekuria R., van Deventer O., Cesar P. Are we in sync?: synchronization requirements for watching online video together // Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI 2011). 2011. P. 311–314. DOI: 10.1145/1978942.1978986.
13. ISO/IEC 23000-19:2018. Information technology – Multimedia application format (MPEG-A) – Part 19: Common media application format (CMAF) for segmented media. 2018. URL: <https://www.iso.org/standard/71975.html> (дата обращения: 11.01.2026).
14. ISO/IEC 23009-1:2022. Information technology – Dynamic adaptive streaming over HTTP (DASH) – Part 1: Media presentation description and segment formats. 2022. URL: <https://www.iso.org/standard/83314.html> (дата обращения: 22.12.2025).
15. ISO/IEC/IEEE 42010:2022. Systems and software engineering – Architecture description. 2022. URL: <https://www.iso.org/standard/74393.html> (дата обращения: 08.01.2026).
16. Keränen A., Holmberg C., Nandakumar S. Interactive Connectivity Establishment (ICE): A Protocol for Network Address Translator (NAT) Traversal. RFC 8445. 2018. URL: <https://www.rfc-editor.org/rfc/rfc8445.html> (дата обращения: 28.12.2025).
17. Mahy R., Matthews P., Rosenberg J. Traversal Using Relays around NAT (TURN): Relay Extensions to Session Traversal Utilities for NAT (STUN). RFC 8656. 2020. URL: <https://www.rfc-editor.org/rfc/rfc8656.html> (дата обращения: 05.01.2026).
18. Mills D., Martin J., Burbank J., Kasch W. Network Time Protocol Version 4: Protocol and Algorithms Specification. RFC 5905. 2010. URL: <https://www.rfc-editor.org/rfc/rfc5905.html> (дата обращения: 17.12.2025).
19. Pantos R., May W. HTTP Live Streaming. RFC 8216. 2017. URL: <https://www.rfc-editor.org/rfc/rfc8216.html> (дата обращения: 10.01.2026).
20. Rescorla E. Security Considerations for WebRTC. RFC 8826. 2021. URL: <https://www.rfc-editor.org/rfc/rfc8826.html> (дата обращения: 23.12.2025).
21. Rosenberg J., Mahy R., Matthews P., Wing D. Session Traversal Utilities for NAT (STUN). RFC 8489. 2020. URL: <https://www.rfc-editor.org/rfc/rfc8489.html> (дата обращения: 06.01.2026).

22. Schulzrinne H., Casner S., Frederick R., Jacobson V. RTP: A Transport Protocol for Real-Time Applications. RFC 3550. 2003. URL: <https://www.rfc-editor.org/rfc/rfc3550.html> (дата обращения: 20.12.2025).
23. Seufert M., Egger S., Slanina M., Zinner T., Hoßfeld T., Tran-Gia P. A Survey on Quality of Experience of HTTP Adaptive Streaming // IEEE Communications Surveys & Tutorials. 2015. Vol. 17, No. 1. P. 469–492. DOI: 10.1109/COMST.2014.2360940.
24. Sodagar I. The MPEG-DASH Standard for Multimedia Streaming Over the Internet // IEEE MultiMedia. 2011. Vol. 18, No. 4. P. 62–67. DOI: 10.1109/MMUL.2011.71.
25. Stockhammer T. Dynamic adaptive streaming over HTTP: standards and design principles // Proceedings of the 2nd Annual ACM Conference on Multimedia Systems (MMSys 2011). 2011. P. 133–144. DOI: 10.1145/1943552.1943572.
26. van Deventer M.O., Stokking H., Hammond M., Le Feuvre J., Cesar P. Standards for Multi-Stream and Multi-Device Media Synchronization // IEEE Communications Magazine. 2016. Vol. 54, No. 3. P. 16–21. DOI: 10.1109/MCOM.2016.7432166.
27. Williams M., Gross K., van Brandenburg R., Stokking H. Inter-Destination Media Synchronization (IDMS) Using the RTP Control Protocol (RTCP). RFC 7272. 2014. URL: <https://www.rfc-editor.org/rfc/rfc7272.html> (дата обращения: 29.12.2025).
28. Williams M., Gross K., van Brandenburg R., Stokking H. RTP: сигнализация источника синхронизации тактовой частоты. RFC 7273. 2014. URL: <https://www.rfc-editor.org/rfc/rfc7273.html> (дата обращения: 07.01.2026).
29. World Wide Web Consortium (W3C). WebRTC: Real-Time Communication in Browsers. URL: <https://www.w3.org/TR/webrtc/> (дата обращения: 16.12.2025).
30. Yin X., Jindal A., Sekar V., Sinopoli B. A Control-Theoretic Approach for Dynamic Adaptive Video Streaming over HTTP // Proceedings of the 2015 ACM Conference on Special Interest Group on Data Communication (SIGCOMM 2015). 2015. P. 325–338. DOI: 10.1145/2785956.2787486.

References

1. Volkova V.N., Denisov A.A. Theory of Systems and Systems Analysis: A University Textbook. 3rd ed. Moscow: Yurait, 2021. Accessed January 12, 2026. <https://urait.ru/bcode/488173>.
2. GOST R 57100-2025. System and Software Engineering. Architecture Description. 2025. Accessed December 18, 2025. <https://docs.cntd.ru/document/1312121066>.
3. GOST R ISO/IEC 25010-2015. Information Technology. Systems and Software Engineering. Systems and Software Quality Requirements and Evaluation (SQuaRE). System and Software Quality Models. 2015. Accessed January 9, 2026. <https://docs.cntd.ru/document/1200121069>.
4. Kozlov V.N. System Analysis, Optimization, and Decision Making: Study Guide. Saint Petersburg: Izd-vo Politekh. un-ta, 2011. Accessed December 21, 2025. <https://elib.spbstu.ru/dl/2/2887.pdf>.
5. Mitra, R., and I. Nadareishvili. Microservices: From Architecture to Release. Saint Petersburg: Piter, 2023.
6. Apple Inc. “Low-Latency HLS.” Accessed January 14, 2026. https://developer.apple.com/documentation/http_live_streaming/using_low-latency_http_live_streaming.
7. Baugher M., McGrew D., Naslund M., Carrara E., Norrman K. “The Secure Real-time Transport Protocol (SRTP).” RFC 3711. 2004. Accessed December 27, 2025. <https://www.rfc-editor.org/rfc/rfc3711.html>.
8. Boronat F., Lloret J., García M. Multimedia group and inter-stream synchronization techniques: a comparative study // Information Systems. 2009. Vol. 34, No. 1. P. 108–131. DOI: 10.1016/j.is.2008.05.001.
9. Clements P., Kazman R., Klein M. Evaluating Software Architectures: Methods and Case Studies. Boston: Addison-Wesley, 2001. 300 p.
10. ETSI TS 103 286-2 V1.1.1. Digital Video Broadcasting (DVB); Companion Screens and Streams; Part 2: Content Identification and Media Synchronization. 2017. URL: https://www.etsi.org/deliver/etsi_ts/103200_103299/10328602/01.01.01_60/ts_10328602v010101p.pdf (дата обращения: 03.01.2026).
11. Fette I., Melnikov A. The WebSocket Protocol. RFC 6455. 2011. URL: <https://www.rfc-editor.org/rfc/rfc6455.html> (дата обращения: 19.12.2025).
12. Geerts D., Vaishnavi I., Mekuria R., van Deventer O., Cesar P. Are we in sync?: synchronization requirements for watching online video together // Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI 2011). 2011. P. 311–314. DOI: 10.1145/1978942.1978986.
13. ISO/IEC 23000-19:2018. Information technology – Multimedia application format (MPEG-A) – Part 19: Common media application format (CMAF) for segmented media. 2018. URL: <https://www.iso.org/standard/71975.html> (дата обращения: 11.01.2026).

14. ISO/IEC 23009-1:2022. Information technology – Dynamic adaptive streaming over HTTP (DASH) – Part 1: Media presentation description and segment formats. 2022. URL: <https://www.iso.org/standard/83314.html> (дата обращения: 22.12.2025).
15. ISO/IEC/IEEE 42010:2022. Systems and software engineering – Architecture description. 2022. URL: <https://www.iso.org/standard/74393.html> (дата обращения: 08.01.2026).
16. Keränen A., Holmberg C., Nandakumar S. Interactive Connectivity Establishment (ICE): A Protocol for Network Address Translator (NAT) Traversal. RFC 8445. 2018. URL: <https://www.rfc-editor.org/rfc/rfc8445.html> (дата обращения: 28.12.2025).
17. Mahy R., Matthews P., Rosenberg J. Traversal Using Relays around NAT (TURN): Relay Extensions to Session Traversal Utilities for NAT (STUN). RFC 8656. 2020. URL: <https://www.rfc-editor.org/rfc/rfc8656.html> (дата обращения: 05.01.2026).
18. Mills D., Martin J., Burbank J., Kasch W. Network Time Protocol Version 4: Protocol and Algorithms Specification. RFC 5905. 2010. URL: <https://www.rfc-editor.org/rfc/rfc5905.html> (дата обращения: 17.12.2025).
19. Pantos R., May W. HTTP Live Streaming. RFC 8216. 2017. URL: <https://www.rfc-editor.org/rfc/rfc8216.html> (дата обращения: 10.01.2026).
20. Rescorla E. Security Considerations for WebRTC. RFC 8826. 2021. URL: <https://www.rfc-editor.org/rfc/rfc8826.html> (дата обращения: 23.12.2025).
21. Rosenberg J., Mahy R., Matthews P., Wing D. Session Traversal Utilities for NAT (STUN). RFC 8489. 2020. URL: <https://www.rfc-editor.org/rfc/rfc8489.html> (дата обращения: 06.01.2026).
22. Schulzrinne H., Casner S., Frederick R., Jacobson V. RTP: A Transport Protocol for Real-Time Applications. RFC 3550. 2003. URL: <https://www.rfc-editor.org/rfc/rfc3550.html> (дата обращения: 20.12.2025).
23. Seufert M., Egger S., Slanina M., Zinner T., Hoßfeld T., Tran-Gia P. A Survey on Quality of Experience of HTTP Adaptive Streaming // IEEE Communications Surveys & Tutorials. 2015. Vol. 17, No. 1. P. 469–492. DOI: 10.1109/COMST.2014.2360940.
24. Sodagar I. The MPEG-DASH Standard for Multimedia Streaming Over the Internet // IEEE MultiMedia. 2011. Vol. 18, No. 4. P. 62–67. DOI: 10.1109/MMUL.2011.71.
25. Stockhammer T. Dynamic adaptive streaming over HTTP: standards and design principles // Proceedings of the 2nd Annual ACM Conference on Multimedia Systems (MMSys 2011). 2011. P. 133–144. DOI: 10.1145/1943552.1943572.
26. van Deventer M.O., Stokking H., Hammond M., Le Feuvre J., Cesar P. Standards for Multi-Stream and Multi-Device Media Synchronization // IEEE Communications Magazine. 2016. Vol. 54, No. 3. P. 16–21. DOI: 10.1109/MCOM.2016.7432166.
27. Williams M., Gross K., van Brandenburg R., Stokking H. Inter-Destination Media Synchronization (IDMS) Using the RTP Control Protocol (RTCP). RFC 7272. 2014. URL: <https://www.rfc-editor.org/rfc/rfc7272.html> (дата обращения: 29.12.2025).
28. Williams M., Gross K., van Brandenburg R., Stokking H. RTP: сигнализация источника синхронизации тактовой частоты. RFC 7273. 2014. URL: <https://www.rfc-editor.org/rfc/rfc7273.html> (дата обращения: 07.01.2026).
29. World Wide Web Consortium (W3C). WebRTC: Real-Time Communication in Browsers. URL: <https://www.w3.org/TR/webrtc/> (дата обращения: 16.12.2025).
30. Yin X., Jindal A., Sekar V., Sinopoli B. A Control-Theoretic Approach for Dynamic Adaptive Video Streaming over HTTP // Proceedings of the 2015 ACM Conference on Special Interest Group on Data Communication (SIGCOMM 2015). 2015. P. 325–338. DOI: 10.1145/2785956.2787486.

Хлопов Андрей Михайлович, кандидат физико-математических наук, доцент, доцент кафедры программного обеспечения вычислительной техники и автоматизированных систем, Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, Россия

Сулханов Илья Игоревич, студент, Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, Россия

Khlopov Andrey Mikhailovich, Candidate of Physical and Mathematical Sciences, Associate Professor, Associate Professor of the Department of Software, Computer Engineering and Automated Systems, Belgorod State Technological University named after V.G. Shukhov, Belgorod, Russia

Sulkhanov Ilya Igorevich, Student of the Department of Software, Computer Engineering and Automated Systems, Belgorod State Technological University named after V.G. Shukhov, Belgorod, Russia

УДК 519.237.8:004.9

DOI: 10.18413/2518-1092-2026-11-2-0-5

Кравцов Г.Г.

**АДАПТИВНАЯ МУЛЬТИ-ИНТЕРВАЛЬНАЯ ШКАЛА (AMIS):
АЛГОРИТМ НОРМАЛИЗАЦИИ АГРЕГИРОВАННЫХ
ДАННЫХ В ЕДИНОМ ИЗМЕРИТЕЛЬНОМ ПРОСТРАНСТВЕ**

Научно-исследовательский Центр «Прикладная статистика»
ул. Шевченко 10/23, г. Рязань, 390005, Россия

e-mail: 62abc@mail.ru

Аннотация

В статье решается проблема методологической некорректности сравнительного анализа разнородных данных, в том числе представленных в агрегированной форме. Существующие методы нормализации либо неприменимы к агрегированным данным, либо не обеспечивают интерпретируемость и метрическую строгость. Предложен метод – развитие авторского подхода адаптивной мульти-интервальной шкалы (AMIS) – программно-методический комплекс для нормализации и сопоставления агрегированных данных. Разработаны алгоритмы преобразования агрегированных данных в репрезентативные выборки (точный и оптимизированный) и механизм обратного преобразования, устанавливающий количественные соответствия между исходными шкалами через универсальную метрику AMIS. Апробация метода выполнена на трёх задачах: нормализация и сопоставление текущих учебных оценок, агрегированных результатов ЕГЭ и макроэкономических показателей ВВП. Результаты демонстрируют, что AMIS создаёт единое метрическое пространство для различных типов данных, обеспечивая корректность арифметических операций и статистически обоснованные соответствия между исходными шкалами. Разработанный подход решает фундаментальную задачу интеграции разнородных агрегированных данных. Открытый программный комплекс (Python, C#, Excel) и верифицированные данные в репозиториях обеспечивают полную воспроизводимость результатов.

Ключевые слова: адаптивная мульти-интервальная шкала (AMIS); нормализация данных; агрегированные данные; обратное преобразование; единое метрическое пространство; сопоставление разнородных метрик; междисциплинарные исследования; образовательная аналитика; экономические индикаторы

Для цитирования: Кравцов Г.Г. Адаптивная мульти-интервальная шкала (AMIS): алгоритм нормализации агрегированных данных в едином измерительном пространстве // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 50-61. DOI: 10.18413/2518-1092-2026-11-2-0-5

Kravtsov G.G.

**ADAPTIVE MULTI-INTERVAL SCALE (AMIS):
A NORMALIZATION ALGORITHM FOR AGGREGATED DATA
IN A UNIFIED METRIC SPACE**

Research Center "Applied Statistics"
10/23 Shevchenko St., Ryazan, 390005, Russia

e-mail: 62abc@mail.ru

Abstract

The article addresses the problem of methodological incorrectness in the comparative analysis of heterogeneous data, including data presented in aggregated form. Existing normalization methods are either inapplicable to aggregated data or fail to ensure interpretability and metric rigor. A method is proposed—an extension of the author's adaptive multi-interval scale (AMIS)—as a software and methodological framework for normalizing and comparing aggregated data. Algorithms have been developed for converting aggregated data into representative samples (exact and optimized), along with an inverse transformation mechanism that establishes quantitative

correspondences between original scales through the universal AMIS metric. The method was tested on three tasks: normalization and comparison of current academic grades, aggregated Unified State Exam results, and macroeconomic GDP indicators. The results demonstrate that AMIS creates a unified metric space for various data types, ensuring the correctness of arithmetic operations and statistically grounded correspondences between the original scales. The proposed approach solves the fundamental problem of integrating heterogeneous aggregated data. The open software suite (Python, C#, Excel) and verified data in repositories ensure full reproducibility of the results.

Keywords: adaptive multi-interval scale (AMIS); data normalization; aggregated data; inverse transformation; unified metric space; comparison of heterogeneous metrics; interdisciplinary research; educational analytics; economic indicators

For citation: Kravtsov G.G. Adaptive Multi-Interval Scale (AMIS): a Normalization Algorithm for Aggregated Data in a Unified Metric Space // Research result. Information technologies. – Т.11, №2, 2026. – P. 50-61. DOI: 10.18413/2518-1092-2026-11-2-0-5

ВВЕДЕНИЕ

Развитие междисциплинарных исследований и аналитики больших данных упирается в фундаментальную проблему интеграции разнородных показателей [6, 23], полученных из различных источников и измеренных в принципиально несопоставимых шкалах. Особую остроту эта проблема приобретает в ситуациях, когда исследователь имеет дело не с первичными, а с данными, уже представленными в агрегированной форме – в виде частотных распределений, сводных таблиц или статистических отчётов.

Классические методы нормализации, такие как линейное шкалирование и стандартизация, обладают существенными ограничениями для решения этой задачи [9, 13, 17, 24]. Линейное шкалирование полностью игнорирует распределение данных внутри диапазона, что приводит к сильным искажениям результатов. Особенно это критично при наличии асимметрии или выбросов. Стандартизация эффективна прежде всего для нормально распределённых данных. Особенность этих подходов – отсутствие в результате единого метрического пространства, сохраняющего семантику исходных данных и как следствие – невозможность корректных арифметических операций между ними после нормализации [25]. Такие методы, как IRT, ориентированы на анализ индивидуальных значений и не могут быть применены напрямую к агрегированным значениям [14], а следовательно, не решают проблему работы с агрегированными данными.

В предыдущей работе [18] представлена адаптивная мульти-интервальная шкала (AMIS), показавшая эффективность работы с разнородными данными в единой метрической системе. Предложенный метод формирует интервальную шкалу, которая учитывает форму распределения исходных данных и обеспечивает методологическую корректность последующих сравнений и вычислений.

Однако в практической аналитике в таких областях, как образовательная статистика [1-3] (например, сопоставления в балльно-рейтинговой системе [7] или работа с агрегированными результатами ЕГЭ), экономика [4], социология, медицина [22], часто отсутствует доступ к первичным данным – либо в силу сложившейся практики публикации, либо по причине наличия персональных данных [11]. Таким образом, исследователь имеет в своём распоряжении лишь их агрегированные значения, что добавляет методологическое препятствие – необходимость адаптации алгоритмов нормализации для работы непосредственно с агрегированными данными. При этом необходимо сохранить точность вычислений.

Настоящая статья посвящена развитию метода AMIS для решения данной проблемы. Цель работы – разработка и апробация программно-методического комплекса, расширяющего метод AMIS для нормализации и сопоставления агрегированных данных. В рамках исследований решаются следующие задачи:

1. Разработка алгоритмов преобразования агрегированных данных в форму, пригодную для нормализации методом AMIS, включая оптимизированные методы для работы с большими выборками.

2. Реализация механизма обратного преобразования для установления точных количественных соответствий между разнородными шкалами через универсальную метрику AMIS.

3. Создание программного инструмента для визуализации и анализа процесса сопоставления, обеспечивающего наглядную верификацию корректности установленных связей.

Предлагаемый подход позволяет не только преодолеть несопоставимость разнородных метрик [18], но и эффективно работать с данными в их агрегированном представлении, что расширяет прикладной потенциал AMIS.

РАЗВИТИЕ МЕТОДА AMIS ДЛЯ РАБОТЫ С АГРЕГИРОВАННЫМИ ДАННЫМИ

Метод AMIS ориентирован на нормализацию первичных данных. Для работы с агрегированными представлениями (частотные распределения, сводные таблицы) требуется его адаптация, что сводится к решению двух задач:

1. Эффективное преобразование агрегированных данных в форму, пригодную для нормализации, без необходимости «разворачивания» полного массива.

2. Разработка механизма обратного преобразования для установления точных соответствий между разнородными шкалами через единую метрику AMIS.

Решение этих задач позволит применять метод к данным в их распространённом виде, существенно расширяя его прикладную ценность.

Для преодоления указанного ограничения в работе предлагается архитектура системы, основанная на методе AMIS [18] и состоящая из трёх ключевых этапов:

1. Восстановление индивидуальных значений из агрегированных данных. На вход системы подаются исходные значения (частотные распределения, сводные таблицы и т.д.). При подготовке нормализации используют два алгоритма, восстанавливающих индивидуальные значения из агрегированных значений: точный метод – полное восстановление распределения – для ограниченного объёма данных, и оптимизированный – пропорциональное моделирование выборки фиксированного размера – для больших массивов.

2. Этап нормализации. Подготовленные данные нормализуются методом AMIS, который конвертирует набор данных в единое метрическое пространство используя шкалу от 0 до 100 сохраняя адаптивность к форме исходного распределения.

3. Последний этап – установление соответствий. Обратное преобразование вычисляет функцию, связывающую значение в шкале AMIS с исходными номинальными показателями. Это устанавливает точное попарное соответствие между разнородными шкалами через шкалу AMIS

Для применения метода AMIS к агрегированным данным необходимо восстановление индивидуальных значений из частотного распределения. В зависимости от объёма исходных данных предлагается два алгоритма.

Для массивов до 10 000 записей применяется метод точного восстановления: на основе каждой пары (значение, частота) формируется соответствующее число копий значения, после чего все копии объединяются в единый массив. Полученный массив полностью повторяет исходное распределение и передаётся на нормализацию AMIS.

Для массивов более 10 000 записей используется оптимизированный метод пропорционального моделирования. Для каждого уникального значения из исходных данных вычисляется его доля, которая затем умножается на 10 000. Так определяется, сколько раз данное значение должно встретиться в итоговой выборке. Например, если значение составляло 15% от общего объёма данных, в выборке из 10 000 элементов оно будет представлено 1500 копиями. После небольшой корректировки округлений (чтобы общая сумма точно сошлась к 10 000) из полученных копий формируется итоговый набор.

Полученная выборка сохраняет пропорции исходного распределения. В результате время обработки перестаёт зависеть от исходного объёма данных.

Алгоритм полного восстановления (точный метод)

Для каждого исходного значения x_i с частотой f_i создаётся f_i копий, которые формируют единый массив:

$$X = \bigcup_{i=1}^m \{x_i\}^{(f_i)}$$

где $\{x_i\}^{(f_i)}$ – множество из f_i копий значения x_i

Метод по умолчанию применяется для наборов данных объёмом до 10 000 записей, для которых полное «разворачивание» массива не приводит к несоразмерному увеличению вычислительных затрат. Восстановленный массив фактически дублирует исходное распределение. Именно он передаётся на нормализацию AMIS.

Метод пропорционального моделирования (оптимизированный метод)

Для массивов, превышающих 10 000 записей, применяется метод пропорционального моделирования.

Пусть агрегированные данные представлены m уникальными значениями x_i с частотами f_i . Общее число наблюдений:

$$N = \sum_{i=1}^m f_i$$

Для каждого значения x_i находится его доля $p_i = f_i / N$.

Количество копий x_i в выборке:

$$k_i = \text{round}(p_i * M)$$

с последующей коррекцией для выполнения условия $\sum k_i = M$. Итоговая выборка формируется объединением мультимножеств:

$$X = \bigcup_{i=1}^m \{x_i\}^{(k_i)}$$

Полученный набор данных сохраняет пропорции исходного распределения, но все дальнейшие расчёты ведутся с выборкой фиксированного объёма.

Нормализация восстановленных данных методом AMIS

К восстановленному массиву X применяется алгоритм нормализации AMIS [18]. На основе итеративно вычисленных контрольных точек $\{x_k\}$ строится кусочно-линейная функция преобразования $f(x)$ [8], отображающая исходные значения в шкалу $[0,100]$. Каждому исходному значению x_i ставится в соответствие нормализованный эквивалент $y_i = f(x_i)$.

В результате исходные агрегированные данные, изначально представленные в несопоставимых шкалах, приводятся к единому метрическому пространству, что делает возможным их корректное сравнение, усреднение и корреляционный анализ.

Построение таблицы соответствия разнородных шкал

Финальным этапом является создание таблицы соответствия между двумя наборами данных, прошедшими независимую нормализацию AMIS. Для каждого набора строится обратная функция $f^{-1}(y)$, восстанавливающая исходное значение x по заданному значению y в универсальной шкале $[0, 100]$. Шкала дискретизируется с шагом 1 балл, и для каждого узла y_j вычисляются соответствующие значения в исходных шкалах:

$$x_{1j} = f_1^{-1}(y_j), \quad x_{2j} = f_2^{-1}(y_j)$$

Результат представляется в виде таблицы: значение в шкале AMIS и соответствующие ему значения в первой и второй исходных шкалах. Полученная таблица позволяет напрямую переводить показатели из одной системы измерений в другую. Это даёт практический инструмент для калибровки результатов.» Обратное преобразование

Обратное преобразование восстанавливает значение в исходной шкале по заданному значению y в шкале AMIS.

Пусть $\{(y_k, x_k)\}_{k=1}^N$ – контрольные точки, полученные при прямом преобразовании, где y_k равномерно распределены на отрезке $[0, 100]$, а x_k – соответствующие им значения в исходной шкале. Тогда для произвольного $y \in [0, 100]$ обратное преобразование $x = f^{-1}(y)$ определяется кусочно-линейной интерполяцией [8]:

$$x = f^{-1}(y) \begin{cases} x_i, & y \leq y_i \\ x_i + \frac{x_{i+1} - x_i}{y_{i+1} - y_i} \cdot (y - y_i), & y_i < y < y_{i+1} \\ x_N, & y \geq y_N \end{cases}$$

где индекс i выбирается из условия $y_i < y < y_{i+1}$. Данная процедура обеспечивает взаимно однозначное соответствие между шкалой AMIS и исходной метрикой.

Программная реализация алгоритма доступна в открытом репозитории проекта [19, 20].

РЕЗУЛЬТАТЫ НОРМАЛИЗАЦИИ И СОПОСТАВЛЕНИЯ РАЗНОРОДНЫХ ДАННЫХ

Сопоставление образовательных метрик

Прямое сравнение и усреднение учебных оценок без нормализации методологически некорректно из-за различий в распределениях как между предметами, так и возрастными группами [5, 7]. Метод AMIS, изначально разработанный для решения этой задачи в рамках Аналитического метода контроля образования (АМКО) [5], позволяет устранить данные искажения путём приведения оценок к единому метрическому пространству.

В настоящем исследовании выполнено сопоставление двух разнородных образовательных показателей: средних учебных оценок по истории в 11 классах ($N = 879$) и агрегированных результатов ЕГЭ по истории за 2025 год ($N = 2377$, частотное распределение с официального портала Минобрнауки Республики Карелия)¹. Для обработки агрегированных данных ЕГЭ применён алгоритм пропорционального моделирования, после чего оба набора нормализованы методом AMIS (рис. 1).

¹ <https://ege.karelia.ru/Default.aspx?pageid=47359> портал Министерства образования Республики Карелия. Распределение баллов ЕГЭ за 2025




Рис. 1. Сопоставление образовательных метрик методом AMIS: нормализация агрегированных данных ЕГЭ (N=2377) и средних учебных оценок по истории (N=879) с установлением функциональных соответствий

Fig. 1. Comparison of educational metrics using the AMIS method: normalization of aggregated Unified State Exam data (N=2377) and average history grades (N=879) with the establishment of functional correspondences

На рис. 2 представлены:

- А – кривые нормализации результатов ЕГЭ,
- В – кривые нормализации учебных оценок,
- С – функциональное соответствие между шкалами,
- D – сравнительное позиционирование показателей в едином метрическом пространстве

AMIS.

Детальная калибровка шкал представлена в файле AMIS_17_table_EGE-history-karelia-2025_Student_Grades_History_Grade11_Raw_Data.xlsx [21]. Фрагмент этой таблицы (Таблица 1) иллюстрирует непрерывное соответствие между баллами AMIS, результатами ЕГЭ и средними учебными оценками.

Таблица 1

Фрагмент соответствия между шкалой AMIS, баллами ЕГЭ и средними учебными оценками по истории

Table 1

Fragment of correspondence between the AMIS scale, Unified State Exam scores, and average history grades

AMIS (0-100)	Балл ЕГЭ	Средняя успеваемость
0	8	3
1	10,851	3,062
2	13,702	3,125
3	16,553	3,187
4	19,404	3,250
5	22,255	3,312
6	25,105	3,374
7	26,630	3,411
8	27,713	3,438
9	...	...

Установленные соответствия носят не произвольный, а статистически обоснованный характер, так как определяются адаптацией метода к форме распределения каждого показателя.

Предложенный подход впервые позволяет установить непрерывное и статистически обоснованное соответствие между агрегированными результатами ЕГЭ и текущими учебными оценками. Ранее подобные сопоставления либо носили экспертный характер, либо опирались на грубое усреднение, игнорирующее форму распределений.

Все исходные данные, результаты нормализации и итоговые таблицы соответствия, включая сопоставление учебных оценок по истории и агрегированных результатов ЕГЭ по истории (Республика Карелия, 2025), доступны в открытом репозитории Harvard Dataverse. Файл AMIS_17_table_EGE-history-karelia-2025_Student_Grades_History_Grade11_Raw_Data.xlsx содержит полную 17-точечную модель нормализации и позволяет полностью воспроизвести полученные результаты [21].

Междисциплинарное сопоставление

В отличие от примера с ЕГЭ, данные ВВП использованы в первичной форме. Это позволяет, во-первых, продемонстрировать универсальность базового метода AMIS [18] при работе с данными различной природы, а во-вторых, наглядно показать саму возможность построения содержательно интерпретируемых соответствий между педагогическими и макроэкономическими показателями (таблица 1).

Реализована нормализация и установление количественных соответствий между средними учебными оценками по истории (N=879) и макроэкономическими показателями - объёмом ВВП стран мира за 2024 год (N=186)² с асимметричным распределением и экстремальными выбросами представляющую особую методическую сложность [10, 12, 16]. На рисунке 2 представлен сравнительный анализ, который содержит кривые нормализации для обоих наборов данных и функциональные соответствия между исходными шкалами через единое пространство AMIS [18].

² GDP (current US\$) <https://data.worldbank.org/indicator/NY.GDP.MKTP.CD>




Рис. 2. Сравнительный анализ нормализации и сопоставления разнородных данных методом AMIS: средние учебные оценки преподавателей (N=879) и объем ВВП стран мира за 2024 год (N=186)

Fig. 2. Comparative analysis of normalization and comparison of heterogeneous data using the AMIS method: average teacher-assigned grades (N=879) and global GDP volume for 2024 (N=186)

Примечание:

- А. Кривые нормализации AMIS для учебных оценок с различной точностью (3, 5, 9, 17 контрольных точек),
- В. Кривые нормализации AMIS для данных ВВП стран мира,
- С. Функциональное соответствие между исходными шкалами учебных оценок и ВВП через единое пространство AMIS,
- Д. Сравнительная позиция показателей в нормализованной шкале AMIS: учебные оценки (синяя линия) и ВВП (оранжевая линия).

Исследования подтвердили корректность метода как при работе с сырыми, так и с агрегированными данными, одновременно продемонстрировав возможность установления точных количественных соответствий между разнородными показателями.

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ НОРМАЛИЗАЦИИ И СОПОСТАВЛЕНИЯ ДАННЫХ

Основным результатом исследования стала адаптация метода AMIS к агрегированной форме представления данных. Точный и оптимизированный алгоритм преобразования распределений в выборки обеспечивают корректную нормализацию там, где прямое применение AMIS было бы невозможно.

Особенно важно то, что предложенный алгоритм гарантирует воспроизводимость результатов для задач нормализации и сопоставления, в отличие от вероятностных методов восстановления данных [15].

Апробация метода на агрегированных данных ЕГЭ ($N = 2377$) подтверждает сохранение статистических свойств исходного распределения. Это позволяет устанавливать математически строгое соответствие с другими образовательными метриками. Как следствие существенно расширяется область применимости AMIS, открывая возможность работы с официальной статистикой, отчётными данными и результатами массовых мониторингов, которые публикуются как правило в агрегированной форме.

Метод AMIS позволяет решать задачу приведения разнородных параметров к единой метрической системе. Наиболее показательным примером является установление количественных соответствий между средними учебными оценками по истории и объёмом ВВП стран мира за 2024 год.

Анализ выявил следующие ключевые соответствия:

- 50 баллов AMIS (центр шкалы): оценка 4.12 балла, ВВП 575 млрд долларов (уровень Швеции, Австрии);
- 75 баллов AMIS (верхний квартиль): оценка 4.42 балла, ВВП 4.06 трлн долларов (уровень Японии, Германии);
- 25 баллов AMIS (нижний квартиль): оценка 3.79 балла, ВВП 108.1 млрд долларов (уровень Пуэрто-Рико, Кении).

Данные соответствия носят не произвольный, а статистически обоснованный характер, поскольку определяются исключительно формой распределения каждого из показателей и не зависят от весов или субъективных экспертных оценок. Построение функциональной связи между несопоставимыми данными демонстрирует потенциал AMIS как инструмента междисциплинарных исследований.

Метод AMIS продемонстрировал высокую эффективность при работе с данными, имеющими разную природу распределения. Для учебных оценок с фиксированной шкалой [5] метод корректно отразил нелинейность распределения. Особенно показательно, что диапазону оценок от 3.0 до 4.12 балла (среднее значение) соответствует 50% шкалы AMIS, тогда как диапазону от 4.12 до 5.0 балла – оставшиеся 50%, что точно отражает распределение относительно среднего значения.

Для данных ВВП с экспоненциальным распределением метод успешно преодолел проблему масштабирования, обеспечив адекватное представление как для экономических гигантов (США, Китай), так и малых экономик за счёт адаптивного разбиения с концентрацией контрольных точек в областях повышенной плотности данных [10].

Разработанный подход открывает возможность создания единой системы мониторинга и корректного сопоставления результатов из различных предметных областей. Метод AMIS позволяет не только нормализовать разнородные данные, но и устанавливать между ними статистически обоснованные количественные соответствия.

В таблице 2 представлены ключевые точки нормализованной шкалы, полученные в результате сопоставления трёх принципиально различных показателей: текущей успеваемости, результатов ЕГЭ и макроэкономических индикаторов (ВВП).

Таблица 2

Соответствие между учебными оценками, баллами ЕГЭ и ВВП в шкале AMIS

Table 2

Correspondence between academic grades, Unified State Exam scores, and GDP in the AMIS scale

Диапазон AMIS	Учебная оценка	Баллы ЕГЭ	ВВП (млрд \$)
0–25	3.0–3.79	8–32.0	0.16–108.1
25–75	3.79–4.42	32.0–70.8	108.1–4060
75–100	4.42–5.0	70.8–100	4060–29185
Центр (50)	4.12	56.76	575

Приведённые примеры демонстрируют, что метод AMIS обеспечивает математически выверенную связь между шкалами принципиально разной природы. Это создаёт основу для разработки объективных критериев в комплексных междисциплинарных исследованиях, интеграцию разнородных показателей в единую систему.

Тем самым подтверждается ключевой тезис работы: адаптивная мульти-интервальная шкала (AMIS) формирует единое измерительное пространство, в котором любые данные – от школьных оценок до макроэкономических показателей – становятся сопоставимыми и могут участвовать в совместном анализе. Представленные примеры с разнородными данными служат эмпирическим доказательством этого положения.

ЗАКЛЮЧЕНИЕ

Проведённое исследование подтвердило, что проблема сопоставления агрегированных разнородных данных является ключевым методологическим барьером для междисциплинарной аналитики. Для её решения разработан и апробирован метод AMIS, центральными элементами которого стали алгоритмы преобразования агрегированных данных в репрезентативные выборки и механизм обратного преобразования, устанавливающий точные количественные соответствия между разнородными шкалами.

В рамках Аналитического метода контроля образования [5] нормализация параметров учебного процесса с помощью AMIS позволила перейти к математическому моделированию образовательного процесса. Метод AMIS является измерительным ядром Аналитического метода контроля образования (АМКО)³, опирающегося на эталонную базу данных 1995–2005 гг. объёмом 2,5 млн записей [5]. Фиксация контрольных точек на основе репрезентативных распределений открывает возможность перехода от нормализации к прогнозированию – в частности, к расчёту ожидаемой успеваемости по косвенным параметрам учебного процесса (нагрузка, интерес, интенсивность занятий, уровень развития учащихся и др.). Данный подход реализуется в рамках программного комплекса «Образовательный конвертер».

Представленные в работе алгоритмы преобразования агрегированных данных и механизм обратного преобразования реализованы в программном коде, который готовится к публикации в открытом репозитории. Ранее опубликованные открытые реализации AMIS [19, 20] ориентированы на работу с первичными (неагрегированными) данными и вместе с верифицированными наборами обеспечивают воспроизводимость базового метода. Развитие программной поддержки для работы с агрегированными данными создаёт основу для дальнейшей адаптации AMIS к потоковым данным и интеграции в конвейеры машинного обучения.

Список литературы

1. Аванесов В.С. Шкалирование тестовых результатов // Педагогические измерения. 2013. № 2. С. 3–21.
2. Гордеева Т.О., Сычев О.А., Сиднева А.Н. Оценивание достижений школьников в традиционной и развивающей системах обучения: психолого-педагогический анализ // Вопросы образования. 2021. № 1. С. 213–236. DOI: 10.17323/1814-9545-2021-1-213-236.
3. Двоерядкина Н.Н., Чалкина Н.А. Стандартизация данных при организации психолого-педагогических исследований // Вестник АмГУ. 2016. № 74.
4. Коклев П.С. Оценка стоимости компании с использованием методов машинного обучения // Финансы: теория и практика. 2022. Т. 26, № 5. С. 132–148. DOI: 10.26794/2587-5671-2022-26-5-132-148.
5. Кравцов Г.Г. Введение в аналитический метод контроля образования (АМКО): от математической аналитики учебного процесса к стандартизированной образовательной базе данных. Рязань: НИЦ «Прикладная статистика», 2025. DOI: 10.5281/zenodo.16791743.

³ О проведении эксперимента по созданию образовательного банка данных в г. Рязани: письмо Министерства образования РФ № 11 от 12.10.1995.

6. Орлов А.И. Теория измерений как часть методов анализа данных // Социология: методология, методы, математическое моделирование. 2012. № 35. С. 155–174.
7. Потанина А.М., Моросанова В.И. Дифференциальные аспекты регуляторных и личностных ресурсов успеваемости учащихся с различными профилями школьной вовлеченности // Theoretical and Experimental Psychology. 2023. Т. 16, № 4. С. 218–239. DOI: 10.11621/ТЕР-23-37.
8. Сорокин А.А. Применение кусочных функций для нормализации входных переменных систем нечеткого вывода // Информационные технологии в управлении. 2021. № 4. С. 70–76. DOI: 10.25728/ru.2021.4.6.
9. Старовойтов В.В., Голуб И.А. Нормализация данных в машинном обучении // Системный анализ и прикладная информатика. 2021. № 3. С. 52–60.
10. Arachchige C.N.P., Prendergast L.A., Staudte R.G. Robust analogs to the coefficient of variation // Journal of Applied Statistics. 2024. Vol. 51, no. 3. P. 576–598. DOI: 10.1080/02664763.2022.2137452.
11. Bonofiglio F., Schumacher M., Binder H. Recovery of original individual person data (IPD) inferences from empirical IPD summaries only: Applications to distributed computing under disclosure constraints // Statistics in Medicine. 2020. Vol. 39, no. 8. P. 1183–1198. DOI: 10.1002/sim.8470.
12. Bruffaerts C., Verardi V., Vermadele C. A generalized boxplot for skewed and heavy-tailed distributions // Statistics & Probability Letters. 2014. Vol. 95. P. 110–117. DOI: 10.1016/j.spl.2014.08.016.
13. Bürkner P.C., Vuorre M. Ordinal Regression Models in Psychology: A Tutorial // Advances in Methods and Practices in Psychological Science. 2023. Vol. 6, no. 1. DOI: 10.1177/25152459231113332.
14. De Ayala R.J. The Theory and Practice of Item Response Theory. 2nd ed. New York: Guilford Press, 2022. 658 p.
15. Heitjan D.F., Rubin D.B. Inference from Coarse Data via Multiple Imputation with Application to Age Heaping // Journal of the American Statistical Association. 1990. Vol. 85, no. 410. P. 304–314. DOI: 10.1080/01621459.1990.10476205.
16. Hubert M., Vandervieren E. An adjusted boxplot for skewed distributions // Computational Statistics & Data Analysis. 2008. Vol. 52, no. 12. P. 5186–5201. DOI: 10.1016/j.csda.2007.11.008.
17. Jain A., Nandakumar K., Ross A. Score normalization in multimodal biometric systems // Pattern Recognition. 2005. Vol. 38, no. 12. P. 2270–2285. DOI: 10.1016/j.patcog.2005.01.012.
18. Kravtsov G. Universal Adaptive Normalization Scale (AMIS): A Methodology for Integrating Heterogeneous Social and Educational Metrics [Preprint]. OSF. 2025. DOI: 10.17605/OSF.IO/BDT2K.
19. Kravtsov G. AMIS_Normalization_Tool [Software] // GitHub. 2026. URL: https://github.com/Famimot/AMIS_Normalization_Tool (дата обращения: 13.02.2026).
20. Kravtsov G. AMIS_Excel_Plugin [Software] // GitHub. 2026. URL: https://github.com/Famimot/AMIS_Excel_Plugin (дата обращения: 13.02.2026).
21. Kravtsov G. Adaptive Multi-Interval Scale (AMIS): Open-Source Software, Source Data and Results for Normalizing and Comparing Raw & Aggregated Metrics [Data set]. Harvard Dataverse. 2025. V1. URL: <https://doi.org/10.7910/DVN/HXSED6> (дата обращения: 13.02.2026).
22. Lu Y., Wang L., Lu J., Yang J., Shen C. A robust data scaling algorithm to improve classification accuracies in biomedical data // BMC Bioinformatics. 2016. Vol. 17, suppl. 13. P. 359. DOI: 10.1186/s12859-016-1236-x.
23. Stevens S.S. On the theory of scales of measurement // Science. 1946. Vol. 103, no. 2684. P. 677–680. DOI: 10.1126/science.103.2684.677.
24. Tao Y., Meng Y., Gao Z., Yang X. Perceived teacher support, student engagement, and academic achievement: A meta-analysis // Educational Psychology. 2022. Vol. 42, no. 4. P. 401–420. DOI: 10.1080/01443410.2022.2033168.
25. van der Linden W.J., ed. Handbook of Item Response Theory, Volume Three: Applications. 1st ed. Boca Raton: Chapman and Hall/CRC, 2022. DOI: 10.1201/9781315117430.

References

1. Avanesov V.S. Scaling of Test Results. Pedagogical Measurements. 2013. No. 2. P. 3–21. (In Russian)
2. Gordeeva T.O., Sychev O.A., Sidneva A.N. Assessment of Schoolchildren's Achievements in Traditional and Developmental Education Systems: A Psychological and Pedagogical Analysis. Educational Studies. 2021. No. 1. P. 213–236. DOI: 10.17323/1814-9545-2021-1-213-236. (In Russian)
3. Dvoeryadkina N.N., Chalkina N.A. Data Standardization in the Organization of Psychological and Pedagogical Research. Bulletin of AmSU. 2016. No. 74. (In Russian)

4. Koklev P.S. Company Valuation Using Machine Learning Methods. Finance: Theory and Practice. 2022. Vol. 26, No. 5. P. 132–148. DOI: 10.26794/2587-5671-2022-26-5-132-148. (In Russian)
5. Kravtsov G.G. Introduction to the Analytical Method of Education Control (AMEC): From Mathematical Analytics of the Educational Process to a Standardized Educational Database. Ryazan: Research Center "Applied Statistics", 2025. DOI: 10.5281/zenodo.16791743. (In Russian)
6. Orlov A.I. Measurement Theory as a Part of Data Analysis Methods. Sociology: Methodology, Methods, Mathematical Modeling. 2012. No. 35. P. 155–174. (In Russian)
7. Potanina A.M., Morosanova V.I. Differential Aspects of Regulatory and Personal Resources of Students' Academic Performance with Different Profiles of School Engagement. Theoretical and Experimental Psychology. 2023. Vol. 16, No. 4. P. 218–239. DOI: 10.11621/TEP-23-37. (In Russian)
8. Sorokin A.A. Application of Piecewise Functions for Normalization of Input Variables in Fuzzy Inference Systems. Information Technologies in Management. 2021. No. 4. P. 70–76. DOI: 10.25728/pu.2021.4.6. (In Russian)
9. Starovoitov V.V., Golub I.A. Data Normalization in Machine Learning. System Analysis and Applied Informatics. 2021. No. 3. P. 52–60. (In Russian)
10. Arachchige C.N.P., Prendergast L.A., Staudte R.G. Robust analogs to the coefficient of variation. Journal of Applied Statistics. 2024. Vol. 51, No. 3. P. 576–598. DOI: 10.1080/02664763.2022.2137452.
11. Bonfiglioglio F., Schumacher M., Binder H. Recovery of original individual person data (IPD) inferences from empirical IPD summaries only: Applications to distributed computing under disclosure constraints. Statistics in Medicine. 2020. Vol. 39, No. 8. P. 1183–1198. DOI: 10.1002/sim.8470.
12. Bruffaerts C., Verardi V., Vermadele C. A generalized boxplot for skewed and heavy-tailed distributions. Statistics & Probability Letters. 2014. Vol. 95. P. 110–117. DOI: 10.1016/j.spl.2014.08.016.
13. Bürkner P.C., Vuorre M. Ordinal Regression Models in Psychology: A Tutorial. Advances in Methods and Practices in Psychological Science. 2023. Vol. 6, No. 1. DOI: 10.1177/25152459231113332.
14. De Ayala R.J. The Theory and Practice of Item Response Theory. 2nd ed. New York: Guilford Press, 2022. 658 p.
15. Heitjan D.F., Rubin D.B. Inference from Coarse Data via Multiple Imputation with Application to Age Heaping. Journal of the American Statistical Association. 1990. Vol. 85, No. 410. P. 304–314. DOI: 10.1080/01621459.1990.10476205.
16. Hubert M., Vandervieren E. An adjusted boxplot for skewed distributions. Computational Statistics & Data Analysis. 2008. Vol. 52, No. 12. P. 5186–5201. DOI: 10.1016/j.csda.2007.11.008.
17. Jain A., Nandakumar K., Ross A. Score normalization in multimodal biometric systems. Pattern Recognition. 2005. Vol. 38, No. 12. P. 2270–2285. DOI: 10.1016/j.patcog.2005.01.012.
18. Kravtsov G. Universal Adaptive Normalization Scale (AMIS): A Methodology for Integrating Heterogeneous Social and Educational Metrics [Preprint]. OSF. 2025. DOI: 10.17605/OSF.IO/BDT2K.
19. Kravtsov G. AMIS_Normalization_Tool [Software]. GitHub. 2026. URL: https://github.com/Famimot/AMIS_Normalization_Tool (accessed: 13.02.2026).
20. Kravtsov G. AMIS_Excel_Plugin [Software]. GitHub. 2026. URL: https://github.com/Famimot/AMIS_Excel_Plugin (accessed: 13.02.2026).
21. Kravtsov G. Adaptive Multi-Interval Scale (AMIS): Open-Source Software, Source Data and Results for Normalizing and Comparing Raw & Aggregated Metrics [Data set]. Harvard Dataverse. 2025. V1. URL: <https://doi.org/10.7910/DVN/HXSED6> (accessed: 13.02.2026).
22. Lu Y., Wang L., Lu J., Yang J., Shen C. A robust data scaling algorithm to improve classification accuracies in biomedical data. BMC Bioinformatics. 2016. Vol. 17, Suppl. 13. P. 359. DOI: 10.1186/s12859-016-1236-x.
23. Stevens S.S. On the theory of scales of measurement. Science. 1946. Vol. 103, No. 2684. P. 677–680. DOI: 10.1126/science.103.2684.677.
24. Tao Y., Meng Y., Gao Z., Yang X. Perceived teacher support, student engagement, and academic achievement: A meta-analysis. Educational Psychology. 2022. Vol. 42, No. 4. P. 401–420. DOI: 10.1080/01443410.2022.2033168.
25. van der Linden W.J., ed. Handbook of Item Response Theory, Volume Three: Applications. 1st ed. Boca Raton: Chapman and Hall/CRC, 2022. DOI: 10.1201/9781315117430.

Кравцов Геннадий Григорьевич, директор, Научно-исследовательский Центр «Прикладная статистика», г. Рязань, Россия

Kravtsov Gennady Grigorievich, Director, Research Center "Applied Statistics", Ryazan, Russia

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И ПРИНЯТИЕ РЕШЕНИЙ ARTIFICIAL INTELLIGENCE AND DECISION MAKING

УДК 004.85

DOI: 10.18413/2518-1092-2026-11-2-0-6

Чмыхало Д.С.
Газизов А.Р.
Легонько О.Л.

**СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ
ПРИ РЕАГИРОВАНИИ НА УГРОЗЫ
ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ**

ФГБОУ ВО «Донской государственный технический университет» (ДГТУ)
пл. Гагарина, 1, г. Ростов-на-Дону, 344002, Россия

e-mail: chmykhalo3009@gmail.com, agazizov@donstu.ru, olga_cvetkova@mail.ru

Аннотация

В современных условиях практически всеобъемлющей цифровизации обеспечение информационной безопасности предприятий и организаций различных форм собственности и областей деятельности становится все более актуальной задачей, требующей использования передовых методов обнаружения и реагирования на угрозы. В данной статье представлена разработанная авторами система поддержки принятия решений, предназначенная для выявления и классификации угроз информационной безопасности, а также автоматизации формирования сценариев реагирования. Предложенная архитектура представляет собой модульную структуру, сочетающую методы машинного обучения, экспертные системы и инструменты объясняющего искусственного интеллекта, что повышает точность идентификации угроз, оценки рисков и усиливает степень доверия специалистов к автоматическим решениям, сформированным интеллектуальной частью системы. В рамках исследования выполнена разработка и тестирование системы с использованием набора данных UNSW-NB15, который содержит информацию о сетевом трафике, сгенерированную в лабораторных условиях. Представленные результаты демонстрируют перспективы внедрения разработанной системы в службы безопасности предприятий, способствуя минимизации ущерба от реализации атак на информационную инфраструктуру в корпоративных и государственных информационных системах. Предложена идея дальнейшего развития системы с учетом расширения датасетов, включающее новые типы угроз и сценариев реагирования, и внедрение онлайн-обучения для адаптации моделей к динамично меняющейся ситуации безопасности.

Ключевые слова: система поддержки принятия решений; технологии искусственного интеллекта; информационная безопасность; защита информации; угроза информационной безопасности

Для цитирования: Чмыхало Д.С., Газизов А.Р., Легонько О.Л. Система поддержки принятия решений при реагировании на угрозы информационной безопасности // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 62-76. DOI: 10.18413/2518-1092-2026-11-2-0-6

Chmykhalo D.S.
Gazizov A.R.
Legonko O.L.

DECISION SUPPORT SYSTEM FOR RESPONDING TO INFORMATION SECURITY THREATS

Don State Technical University
1 Gagarin square, Rostov-on-Don, 344003, Russia

e-mail: chmykhalo3009@gmail.com, agazizov@donstu.ru, olga_cvetkova@mail.ru

Abstract

In today's increasingly digitalized world, ensuring information security for enterprises and organizations across various business types and industries is becoming an increasingly pressing issue, requiring advanced threat detection and response methods. This article presents a decision support system developed by the authors for identifying and classifying information security threats and automating the generation of response scenarios. The proposed architecture is a modular structure combining machine learning methods, expert systems, and explanatory artificial intelligence tools, which improves the accuracy of threat identification and risk assessment and enhances the confidence of specialists in the automated decisions generated by the system's intelligent component. The study included developing and testing the system using the UNSW-NB15 dataset, which contains network traffic information generated under laboratory conditions. The presented results demonstrate the potential for implementing the developed system in enterprise security services, helping to minimize damage from attacks on the information infrastructure of corporate and government information systems. An idea is proposed for further development of the system, taking into account the expansion of datasets, including new types of threats and response scenarios, and the introduction of online learning to adapt models to the dynamically changing security situation.

Keywords: expert system; artificial intelligence technologies; information security; information protection; information security threat

For citation: Chmykhalo D.S., Gazizov A.R., Legonko O.L. Decision Support System for Responding to Information Security Threats // Research result. Information technologies. – Т.11, №2, 2026. – P. 62-76. DOI: 10.18413/2518-1092-2026-11-2-0-6

ВВЕДЕНИЕ

В настоящее время в условиях масштабного использования электронного документооборота во всех подразделениях и бизнес-процессах предприятия, постоянного совершенствования угроз и расширения видов атак на информационную инфраструктуру, появляется необходимость решения актуальной задачи разработки новых эффективных средств защиты информационной инфраструктуры [1]. Решению этой задач посвящено множество научных работ, в которых авторы рассматривают одно из самых перспективных направлений в этой отрасли – это внедрение технологий искусственного интеллекта.

Одной из заслуживающих научных работ в этой области является статья [2], в которой авторы проанализировали множество научных публикаций за 2018-2023 годы. Они отмечают, что при построении систем защиты с использованием искусственного интеллекта в целом наблюдается повышение их эффективности. Это происходит за счет того, что ряд операций анализа угроз выполняется системой, а не человеком. Однако, вместе с тем, исследователи говорят и о возможных рисках: для успешной работы таких систем нужны качественные обучающие данные, что является основой для проведения дальнейших исследований в этом направлении.

В научных исследованиях [3-6] авторы анализируют возможности применения искусственного интеллекта в сфере защиты конфиденциальной информации, для выявления аномалий в информационных системах, и поднимают очень важный вопрос, который, по сути, должен вставать во всех областях при использовании искусственного интеллекта – необходимость анализа и контроля решений, принимаемых системой, и акцентируют внимание на проблеме обеспечения прозрачности процессов принятия этих решений. Эти исследования демонстрируют,

что технологии искусственного интеллекта обладают потенциалом, позволяющим значительно повысить эффективность автоматизированных систем защиты, обеспечить работу в режиме реального времени и снизить влияние человеческой ошибки.

Далее стоит упомянуть исследования, представленные в работах [7, 8], в которых помимо обсуждения преимуществ, рассматриваются также проблемы и ограничения, связанные с внедрением методов машинного обучения, глубокого обучения и обучения с подкреплением в информационную безопасность. Авторы указывают, что, хотя эти технологии улучшают обнаружение угроз, их внедрение требует выявления возникающих уязвимостей и потенциального неправомерного использования, чтобы системы можно было защищать более прозрачно и эффективно.

Другим примером, подтверждающем актуальность данной темы является работа [9], в которой авторы провели обзор литературы с использованием данных из таких поисковых систем, как Google Scholar, ResearchGate, ScienceDirect, IEEE Xplore, Digital Library и Microsoft Academic, для оценки возможностей искусственного интеллекта в информационной безопасности. И в итоге, авторы сделали основной вывод, заключающийся в том, что использование искусственного интеллекта имеет значительные преимущества по сравнению с традиционными подходами при защите информации.

Наконец, еще одним уместным примером, который стоит упомянуть в контексте рассматриваемой задачи, является научная работа [10], в котором представлен систематический обзор текущего состояния объяснимого искусственного интеллекта (Explainable Artificial Intelligence, XAI) и его актуальности для информационной безопасности. На основе проводимых исследований авторы приходят к выводу, что разработка и применение объяснимого искусственного интеллекта могут значительно улучшить как понимание, так и эффективность защитных мер.

Множество современных предприятий из различных отраслей деятельности используют системы управления информацией о безопасности (Security Information and Event Management, SIEM), которые помогают отслеживать и защищать их информационную инфраструктуру. Однако у этих систем есть свои ограничения: они часто бывают дорогими и требуют значительных усилий для адаптации под особенности конкретного предприятия. Кроме того, в некоторых случаях возникает зависимость от определенных торговых марок, что создает дополнительные сложности. Таким образом, перспективным решением становится создание собственной, индивидуально разработанной системы поддержки принятия решений (СППР).

Изучению вопросов применения систем поддержки принятия решений в различных областях посвящено множество научных работ авторов. Одной из популярных областей деятельности, в которую активно внедряются технологии искусственного интеллекта является сфера информационной безопасности.

Научная статья [11] посвящена вопросу использования систем поддержки принятия решений в различных отраслях экономики. Автор выполнил анализ некоторых реализованных проектов развития систем поддержки принятия решений на российских предприятиях.

В статье [12] поднимается вопрос синтеза технологий искусственного интеллекта и СППР, который позволит оптимизировать процесс принятия решений на основе взаимодействия нейронных сетей с нечеткими (размытыми) системами и элементами управления. Автор на примере задачи управления проектами показывает основные роли, которые может исполнять искусственный интеллект (ассистент руководителя, советник, методолог). Предлагаются варианты использования интеллектуальных систем и типов решений в проектной деятельности.

В статье [13] рассматриваются подсистема принятия решений и использование методов искусственного интеллекта для реализации этапов принятия решений в ситуационном центре.

В работе [14] приводится описание системы поддержки принятия решений при обеспечении информационной безопасности системы верхнего уровня автоматизированной системы

управления технологическими процессами атомной электростанции. Задача системы заключается в поиске и ранжировании конфигураций средств защиты информации.

Работа [15] посвящена исследованию вопроса актуальности внедрения систем поддержки принятия решений в процессы управления современными предприятиями. Рассмотрена классификация видов современных систем поддержки принятия решений, а также сформулированы особенности и проблемы применения искусственных нейронных сетей в системах поддержки принятия решений.

В статье [16] рассматривается задача обеспечения информационной безопасности автоматизированных систем управления технологическими процессами промышленных объектов. Исследования в статье направлены на совершенствование процедуры количественной оценки рисков информационной безопасности. Представлены архитектура интеллектуальной системы поддержки принятия решений и программная реализация инструментальных средств автоматизации моделирования сценариев атак и оценки рисков.

В научной работе [17] выполнен обзор публикаций, посвященных проблеме эффективного применения обученных искусственных нейронных сетей в решении задач классификации, прогнозирования и управления. Рассмотрены особенности и выполнен сравнительный анализ популярных структур нейронных сетей и методик формирования обучающих выборок.

В работе [18] рассматривается задача проектирования информационной системы поддержки принятия решений при разработке систем защиты объектов информатизации. Предлагается использование методов разработки моделей функционирования защищенных информационных систем в условиях деструктивного воздействия на основе байесовских сетей.

В работе [19] предложена архитектура прототипа интеллектуальной системы для автоматизированной поддержки принятия решений, моделирования сценариев атак и оценки рисков информационной безопасности промышленной системы управления, что повышает точность и скорость оценки рисков и помогает выбрать эффективные меры защиты на всех этапах жизненного цикла объекта и систем его защиты.

В статье [20] предложена методика оценки защищенности сложных систем с системой поддержки принятия решений, основанная на SWOT-анализе и логико-вероятностном методе, для выявления угроз нарушения критических свойств средств криптографической защиты. Эта модель позволяет оперативно обнаруживать объекты в опасном состоянии и информировать о необходимости мер безопасности.

Целью исследования, проводимого в настоящей статье, является разработка концептуального проекта системы поддержки принятия решений, предназначенной для автоматизации процесса принятия решений в условиях воздействия угроз информационной безопасности на инфраструктуру предприятия. При этом объектом исследования будут выступать процессы реагирования на угрозы информационной безопасности, а предметом исследования – проект системы поддержки принятия решений при реагировании на угрозы информационной безопасности.

АРХИТЕКТУРА ПРОЕКТИРУЕМОЙ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ

Архитектура проектируемой системы поддержки принятия решений построена из следующих основных модулей (рисунок 1):

1. Модуль сбора данных выполняет автоматический сбор конфигурационных параметров источников данных (журналы событий, данные о сетевом трафике, данные о конфигурации и пользователей).

Модуль использует протоколы и программный интерфейс (Application Programming Interface, API) для интеграции с системами мониторинга и управления событиями, системами обнаружения

и предотвращения вторжений, антивирусным программным обеспечением, системами управления доступом.

Передает информацию о событиях и инцидентах в Модуль обнаружения угроз.

2. Модуль обнаружения угроз выполняет идентификацию и классификацию угроз на основе информации о событиях и инцидентах (от Модуля сбора данных), информации о типах угроз и сигнатурах атак (из Базы данных).

Передает перечень обнаруженных угроз с их классификацией в Модуль оценки рисков.

3. Модуль оценки рисков выполняет оценку уровня риска для каждой угрозы (высокий, средний, низкий) на основе перечня обнаруженных угроз (от Модуля обнаружения угроз), информации о ценности активов предприятия (из Базы данных) и информация о вероятностях реализации угроз (из Базы данных).

Передает результаты оценок уровней риска для обнаруженных угроз в Модуль поддержки принятия решений.

Возвращает оператору системы (сотруднику службы безопасности предприятия) результаты оценки.

4. Модуль поддержки принятия решений на основе оценок рисков (от Модуля оценки рисков), сценариев реагирования на угрозы и их эффективности (из Базы знаний) и исторических данных о последствиях прошлых инцидентов (из Базы данных), вырабатывает рекомендуемые сценарии реагирования на угрозы.

Возвращает оператору системы (сотруднику службы безопасности предприятия) рекомендуемые сценарии реагирования на угрозы.

При необходимости оператор системы может выполнить уточнение рекомендуемых сценариев путем взаимодействия с Модулем поддержки принятия решений.

Также Модуль поддержки принятия решений передает информацию о необходимых автоматических действиях в системы управления и безопасности для немедленного выполнения. Эти действия могут включать блокировку подозрительных IP-адресов, отключение уязвимых сервисов и другие меры, направленные на быстрое устранение угроз. Передача этой информации обеспечивает оперативное реагирование на инциденты, минимизируя потенциальные убытки и риски для предприятия.

5. Модуль управления знаниями включает в себя Базу данных и Базу знаний, которые используются Модулем обнаружения угроз, Модулем оценки рисков и Модулем поддержки принятия решений.

Предлагаемая архитектура обеспечивает системный подход к автоматизации процессов выявления и реагирования на угрозы информационной безопасности с использованием современных методов анализа данных, моделирования и оптимизации.




Рис. 1. Архитектура системы поддержки принятия решений при реагировании на угрозы информационной безопасности

Fig. 1. Architecture of the decision support system for responding to information security threats

МЕТОДЫ РЕАЛИЗАЦИИ МОДУЛЕЙ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ПРИ РЕАГИРОВАНИИ НА УГРОЗЫ

1. Модуль сбора данных.

Модуль сбора данных отслеживает сетевой трафик, действия пользователей, системные логи и другие источники информации, выполняют сбор данных из сетевых устройств, серверов, приложений и устройств конечных пользователей. Затем собранные данные проходят первичную фильтрацию для удаления шумов и нерелевантной информации. Например, исключаются незначительные события.

Далее из каждого события определяются ключевые признаки, которые характеризуют его с точки зрения безопасности информации.

После обработки каждое событие представляется в виде набора (вектора) числовых значений признаков.

2. Модуль обнаружения угроз.

Модуль обнаружения угроз предлагается построить на основе использования модели градиентного бустинга XGBoost (eXtreme Gradient Boosting), которая позволяет получить предсказания типов угроз (классов атак) для каждого сетевого события на основе обучения системы по признакам атак, включая вероятности принадлежности к каждому из классов угроз, что обеспечивает интерпретируемость результатов через такие метрики точности, как accuracy, precision, recall и confusion matrix. Эти предсказания затем передаются в Модуль оценки рисков для расчета уровня угрозы.

3. Модуль оценки рисков.

В Модуле оценки рисков выполняется аналитический расчет уровня риска по следующей формуле:

$$\text{уровень риска} = \text{вероятность угрозы} \times \text{потенциальный ущерб},$$

где вероятность угрозы – значения в диапазоне от 0 до 1;

потенциальный ущерб – значения в условных единицах.

При этом исходными данными являются значения вероятностей реализации угроз и соответствующий им потенциальный ущерб. Эти данные могут быть получены путем проведения экспертной оценки действующей на предприятии системы защиты и взаимодействия с финансово-экономическими подразделениями.

Также, предварительно, специалисты службы защиты информации предприятия должны определить пороговые значения уровня риска, таким образом, чтобы получить результаты оценки риска в качественном виде – в виде категорий риска. Наиболее популярный вариант решения подобной задачи заключается в задании трех категорий: высокий, средний и низкий риск.

4. Модуль поддержки принятия решений.

Модуль поддержки принятия решений предлагается реализовать с помощью машинного обучения на основе модели градиентного бустинга, обученной на исторических данных инцидентов, которая позволит автоматически выявлять закономерности и рекомендовать наиболее подходящие сценарии реагирования. Модель анализирует признаки: класс угрозы, категорию риска, и на выходе формируются рекомендации по сценариям реагирования.

Таким образом, исходя из приведенного описания методов реализации модулей системы поддержки принятия решений, следует, что в проектируемой системе интеллектуальными являются Модуль обнаружения угроз и Модуль поддержки принятия решений (таблица 1).

Таблица 1

Методы реализации модулей системы поддержки принятия решений

Table 1

Methods for implementing modules of the decision support system

Модуль	Входные данные	Выходные данные	Методы
Модуль сбора данных	Данные из источников (логи SIEM, сетевой трафик, действия пользователей, системные логи, конфигурации устройств, серверов и приложений, Threat Intelligence, исторические инциденты)	Нормализованные числовые векторы признаков и текстовые описания событий (логи)	ETL-процессы с использованием библиотек Pandas и NumPy (без применения искусственного интеллекта)
Модуль обнаружения угроз (интеллектуальный)	Структурированные векторы от Модуля сбора данных Информация о типах угроз и сигнатурах атак (для демонстрации используется набор данных UNSW-NB15)	Перечень обнаруженных угроз с их классификацией	Машинное обучение на основе модели градиентного бустинга XGBoost (eXtreme Gradient Boosting)

Модуль	Входные данные	Выходные данные	Методы
Модуль оценки рисков	Перечень обнаруженных угроз с их классификацией Информация о ценности активов предприятия Информация о вероятностях реализации угроз	Оценки уровней риска для обнаруженных угроз	Аналитический расчет уровня риска: $\text{уровень риска} = \text{вероятность угрозы} \times \text{потенциальный ущерб}$
Модуль поддержки принятия решений (интеллектуальный)	Перечень обнаруженных угроз с их классификацией Оценки уровней риска для обнаруженных угроз Реализованные в прошлом сценарии реагирования на угрозы и их эффективность Исторические данные о последствиях прошлых инцидентов	Рекомендуемые сценарии реагирования на угрозы	Машинное обучение на основе модели градиентного бустинга XGBoost (eXtreme Gradient Boosting)

РЕАЛИЗАЦИЯ ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ

В качестве программного средства реализации проектируемой системы поддержки принятия решений был выбран язык программирования Python – одно из самых популярных и универсальных средств для разработки интеллектуальных систем и анализа данных. Python широко используется в области машинного обучения, обработки данных и искусственного интеллекта благодаря обширной системе библиотек и активному сообществу разработчиков. Для реализации системы используются библиотеки: XGBoost (для модели решений), Pandas и NumPy (для обработки данных), Matplotlib (для визуализации матрицы ошибок), Scikit-learn (для метрик и нормализации).

На начальном этапе необходимо получить данные для обучения интеллектуальных модулей системы. На практике данные для обучения Модуля обнаружения угроз извлекаются из систем мониторинга, SIEM-систем, базы Threat Intelligence, внутренней документации и аналитики безопасности, для обучения Модуля поддержки принятия решений – из логов SIEM-систем, базы данных инцидентов, исторических отчетов внутренних систем, открытых датасетов (таблица 2).

Таблица 2

Данные для обучения интеллектуальных модулей системы поддержки принятия решений
(при практической реализации и внедрении системы)

Table 2

Data for intelligent training modules of the decision support system
(during practical implementation and introduction of the system)

№	Источник данных	Данные, которые собираются	Цель использования
Модуль обнаружения угроз			
1	Журналы событий системы (лог-файлы)	Временные метки, типы событий, уровни тревоги, детали событий	Обнаружение аномалий и классификация угроз
2	Сетевой трафик	Пакеты данных, источники и назначения, протоколы, объемы	Анализ активности сети, выявление подозрительных соединений
3	Данные о конфигурациях устройств и систем	Настройки, версии, активированные модули, патчи	Идентификация уязвимостей и известных атак
4	Данные о пользователях и их действиях	Время входа/выхода, права доступа, действия пользователя	Детектор подозрительных активностей и инсайдерских угроз
5	Прошлые инциденты, известные угрозы, сигнатуры	Метки угроз, сигнатуры атак, описания, идентификаторы	Обучение модели на известных атаках
6	Информация о текущих сессиях, соединениях	Активные соединения, длительность, попытки входа	Обнаружение аномальной активности, связанной с атакой
Модуль поддержки принятия решений			
7	Логи SIEM-систем	Исторические записи инцидентов, уровни рисков, принятые решения, временные метки, типы угроз	Обучение модели формировать сценарии реагирования на основе комбинации угроз и рисков
8	Базы данных инцидентов (например, NIST, MITRE ATT&CK)	Анонимизированные кейсы инцидентов, метки решений, уровни серьезности, исходы реагирования	Составление обучающего датасета для классификации решений и оценки рисков
9	Исторические отчеты внутренних систем (SOC, firewall)	Отчеты о прошлых инцидентах, экспертные аннотации решений, метрики эффективности реагирования	Анализ паттернов для обучения модели формированию последовательности оптимальных действий
10	Открытые датасеты для машинного обучения	Адаптированные данные о трафике, угрозах и решениях, с балансировкой классов	Начальное обучение и тестирование модели на синтетических/реальных данных

Для демонстрации процессов обучения и тестирования проектируемой системы поддержки принятия решений используется набор данных UNSW-NB15, содержащий информацию о сетевом трафике, сгенерированную в лабораторных условиях Австралийского университета Нового Южного Уэльса (UNSW) с использованием инструмента IXIA PerfectStorm [21]. Набор включает обычный сетевой трафик (нормальные события), и данные девяти атак (Fuzzers, Analysis, Backdoors, DoS, Exploits, Generic, Reconnaissance, Shellcode and Worms), что делает его полезным для обучения и тестирования систем обнаружения вторжений. В наборе подготовлены обучающий (тренировочный) и тестовый массивы, хранящиеся в двух файлах. Каждое событие описывается 49 признаками, которые включают в себя обычные, потоковые, временные, контентные и другие характеристики трафика.

Для обучения модуля поддержки принятия решений генерируются синтетические исходные данные для моделирования реальных сценариев, где типы угроз и категории риска влияют на рекомендации для специалистов службы безопасности. Было сгенерировано 3000 событий – по 100 событий для каждой из 30 комбинаций (10 типов угроз $\times$ 3 категории риска).

В итоге получается, что исходные данные состоят из следующих признаков:

- threat_type – классы событий, которые были предсказаны в результате запуска Модуля обнаружения угроз;
- risk_category – категории рисков ('низкий', 'средний' и 'высокий'), которые были рассчитаны в результате запуска Модуля оценки рисков. При этом учитывались заданные пороги риска (менее 30%, 30-70% и более 70% от стоимости активов соответственно);
- decision – массив заданных рекомендаций по действиям, поставленных в соответствие с комбинациями угроза + риск. Массив формируется на основе анализа экспертных знаний.

В сформированные таким образом синтетические данные необходимо добавить шум для того, чтобы имитировать реальные условия принятия решений в системах обнаружения вторжений. Это позволит учесть не идеальность рекомендаций, которая возможна из-за человеческого фактора или неполной информации, а также снизит вероятность переобучения системы, заставляя модель учитывать не только идеальные сценарии, но и возможные отклонения, улучшая ее устойчивость к непредвиденным ситуациям. В системах обнаружения вторжений (Intrusion Detection System, IDS), где истинные решения часто субъективны и зависят от контекста, шум отражает эту неопределенность, делая предсказания более реалистичными и полезными для операторов.

В реальности такие данные могут быть получены из журналов систем обнаружения вторжений, анализа сетевого трафика и баз данных реагирования на инциденты, предоставляемых организациями.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

Разработанная система поддержки принятия решений прошла комплексное тестирование на наборе данных UNSW-NB15 и синтетических данных, предназначенных для обучения модуля принятия решений, и моделирующих признаки реальных атак и принципы реагирования на инциденты. Полученные результаты подтверждают практическую применимость системы для внедрения в корпоративную инфраструктуру, для обеспечения поддержки специалистам службы безопасности в процессе анализа сетевых событий.

Модуль обнаружения угроз, реализованный на основе алгоритма XGBoost и обученный на наборе данных UNSW-NB15, демонстрирует общую точность классификации 66,07% при тестировании на 82332 событиях (рисунок 2). Взвешенные средние метрики составляют: точность (precision) 86%, полнота (recall) 66% и F1-мера 72%, что указывает на хорошую производительность для доминирующих классов атак. Однако макро-средние значения (точность 45%, полнота 62%, F1-мера 44%) показывают дисбаланс в данных и проблемы с редкими классами.

... Модуль обнаружения угроз (XGBoost):
Accuracy: 0.6607
Отчет по классификации для Модуля обнаружения угроз:

	precision	recall	f1-score	support
Normal	0.02	0.12	0.04	677
Reconnaissance	0.06	0.37	0.11	583
Analysis	0.34	0.41	0.37	4089
Fuzzers	0.84	0.51	0.64	11132
Backdoor	0.25	0.63	0.36	6062
Exploits	1.00	0.96	0.98	18871
DoS	1.00	0.58	0.73	37000
Generic	0.85	0.84	0.85	3496
Shellcode	0.08	0.87	0.14	378
Worms	0.09	0.89	0.17	44
accuracy			0.66	82332
macro avg	0.45	0.62	0.44	82332
weighted avg	0.86	0.66	0.72	82332

Confusion Matrix для Модуля обнаружения угроз:

[	81	180	358	58	0	0	0	0	0	0]
[	76	217	261	9	9	0	0	0	11	0]
[	543	1051	1690	492	164	8	2	35	83	21]
[	720	1246	1773	5708	755	0	2	415	282	231]
[	199	476	624	35	3846	0	2	19	821	40]
[	7	44	124	280	193	18172	1	4	27	19]
[	2102	20	27	158	10578	0	21383	25	2674	33]
[	53	144	156	45	19	4	2	2937	105	31]
[	0	5	0	3	38	0	0	2	327	3]
[	0	0	0	1	3	0	0	0	1	39]]

Рис. 2. Результаты обучения и тестирования Модуля обнаружения угроз
Fig. 2. Results of training and implementation of the Threat Detection Module

После обучения и проверки Модуля принятия решений получилась модель, которая показывает умеренную способность классифицировать сценарии реагирования на угрозы информационной безопасности, и правильно определяет, как реагировать на угрозы в 67% случаев (рисунок 3). Таким образом, основываясь на полученных результатах тестирования разработанной системы поддержки принятия решений, можно заключить, что эта система позволит специалистам служб безопасности предприятий уделять особое внимание потенциально опасным событиям, т.е., тем, которые могут иметь высокие риски и представляют угрозу для штатного функционирования предприятия. Это возможно за счет снабжения сотрудников информацией о спектре возможных действий при возникновении определенных событий.

В контексте проводимых в данной научной работе исследований, также следует указать на тот факт, что в научной литературе многие авторы подчеркивают важную роль, которую современные технологии искусственного интеллекта играют в решении задачи автоматизации процессов анализа угроз информационной безопасности, что, соответственно, подтверждает актуальность проведения исследований в этой области. Например, в научной статье [22] подчеркивается необходимость выполнения автоматизации задач, которые решают специалисты службы безопасности, с использованием искусственного интеллекта. Внедрение интеллектуальных технологий преследует цель повышения эффективности обнаружения и скорости реагирования на угрозы информационной безопасности. Основная мысль работы заключается в том, что хотя интеллектуальные технологии могут улучшить функционирование центров управления безопасностью (Security Operations Center, SOC), их применение требует человеческого мониторинга для снижения потенциальных рисков.

Отраслевые обзоры, такие как на онлайн-ресурсе CSO Online, подчеркивают необходимость автоматизации процессов анализа событий и инцидентов информационной безопасности для борьбы с растущими угрозами (52% организаций регистрируют увеличение количества угроз и инцидентов), отмечая текущий уровень автоматизации (46% значительно, 44% частично),

препятствия (39% нехватка навыков, 21% незрелость процессов) и преимущества (снижение времени реагирования и повышение точности) [23].

Точность модели решений на данных от модулей: 0.6658

Отчет по классификации на данных от модулей:

	precision	recall	f1-score	support
Analyze and block and Notify admin	0.00	0.00	0.00	563
Block and Notify admin	0.08	0.43	0.13	607
Block and fix vulnerability	0.00	0.00	0.00	2528
Block and isolate and Notify admin	0.00	0.00	0.00	1372
Fix vulnerability	0.00	0.00	0.00	1137
Full isolation and Notify admin	0.08	0.97	0.14	338
Full traffic blocking and Notify admin	0.00	0.00	0.00	1647
Ignore	1.00	0.58	0.73	37000
Investigate	1.00	0.98	0.99	18489
Isolate and block and Notify admin	0.83	0.80	0.81	7508
Limit traffic	0.34	0.91	0.49	1862
Monitor	0.44	1.00	0.61	3161
Monitor and analyze	0.00	0.00	0.00	537
Monitor traffic	0.00	0.00	0.00	800
Quarantine	0.00	0.00	0.00	38
Quarantine and delete and Notify admin	0.00	0.00	0.00	3
Restrict access	0.00	0.00	0.00	270
Restrict and monitor	0.25	0.86	0.38	4470
Scan	0.00	0.00	0.00	2
accuracy			0.67	82332
macro avg	0.21	0.34	0.23	82332
weighted avg	0.79	0.67	0.68	82332

Рис. 3. Результаты обучения и тестирования Модуля принятия решений
Fig. 3. Results of training and implementation of the Decision-making Module

В отличие от традиционных автоматизированных систем мониторинга, которые в основном участвуют в обнаружении угроз и предупреждении, предложенная система представляет собой комплексную модульную архитектуру, включающую механизмы классификации, оценки рисков, а также генерации сценариев реагирования.

Таким образом, можно заключить, что полученные результаты подтверждают эффективность разработанной системы поддержки принятия решений, позволяющей реализовать оперативное реагирование на угрозы, и формирование обоснованных решений.

ЗАКЛЮЧЕНИЕ

В результате проведенного исследования была разработана система поддержки принятия решений на основе алгоритмов машинного обучения. Особенностью системы стала ее реализация на основе модульной архитектуры, позволяющей гибко настраивать и модернизировать систему под задачи и потребности внедрения в компьютерной сети предприятия. Система может автоматически формировать сценарии реагирования на атаки, что особенно актуально в современных условиях эволюции угроз информационной безопасности. Таким образом, разработанная система позволит сотрудникам службы безопасности своевременно замечать и реагировать на события безопасности в компьютерной сети предприятия, снизить эффект и последствия влияния человеческого фактора на общую защищенность системы.

В качестве дальнейшего развития и совершенствования системы мы считаем рационально будет выполнить расширение датасетов образцами угроз и вариантами реагирования на них. Это можно реализовать с помощью интеграции системы с реальными данными SOC для обеспечения практической применимости системы в реальных условиях функционирования систем защиты информации. Также вполне обоснованным будет внедрение в архитектуру системы дополнительного модуля, который будет решать задачу объяснимого искусственного интеллекта

(SHapley Additive exPlanations, SHAP), что позволит повысить доверие специалистов к получаемым автоматизированным решениям.

Список литературы

1. Голикова А.А., Мишина Н.А. Угрозы кибербезопасности в условиях цифровизации бизнес-процессов // Актуальные проблемы и тенденции развития современной экономики: Сборник материалов Международной научно-практической конференции, Самара, 28–29 октября 2024 года. – Самара: Самарский государственный технический университет, 2024. – С. 433–437. – EDN АНСУАУ.
2. Jada Irshaad, Mayayise Thembekele. The impact of artificial intelligence on organisational cyber security: An outcome of a systematic literature review. Data and Information Management. – 2023. – 8(2) – 100063. 10.1016/j.dim.2023.100063.
3. Santos R., Boente A., Ferreira V., Boente R., Luz D., Duarte L., Santos A., Vasconcelos G. Artificial intelligence and cybersecurity: A study of artificial intelligence in cybernetic defense // ARACÊ. – 2025. – No. 7. – P. 23155–23178. – DOI: 10.56238/arev7n5-133.
4. Mohamed N. Artificial intelligence and machine learning in cybersecurity: A deep dive into state-of-the-art techniques and future paradigms // Knowledge and Information Systems. – 2025. – Vol. 67. – No. 6969–7055. – DOI: 10.1007/s10115-025-02429-y.
5. Lysenko S. The Role of Artificial Intelligence in Cybersecurity: Automation of Protection and Detection of Threats. Economic Affairs. 2024. – 69. – 10.46852/0424-2513.1.2024.6.
6. Manoj Nair Meghna, Deshmukh Atharva, Tyagi Amit. Artificial Intelligence for Cyber Security: Current Trends and Future Challenges. – 2023. – 10.1002/9781394213948.ch5.
7. Ozkan Merve, Akin Erdal, Aslan Ömer, Kosunalp Selahattin, Iliev Teodor, Stoyanov Ivaylo. A Comprehensive Survey: Evaluating the Efficiency of Artificial Intelligence and Machine Learning Techniques on Cyber Security Solutions. IEEE Access. PP. – 2024. – 10.1109/ACCESS.2024.3355547.
8. Naik Binny, Mehta Ashir, Yagnik Hiteshri, Shah Manan. The impacts of artificial intelligence techniques in augmentation of cybersecurity: a comprehensive review. Complex & Intelligent Systems. – 2021. – 8. 10.1007/s40747-021-00494-8.
9. Akhtar Muhammad, Feng Tao. An overview of the applications of Artificial Intelligence in Cybersecurity. EAI Endorsed Transactions on Creative Technologies. – 2021. – 172218. 10.4108/eai.23-11-2021.172218.
10. Rjoub Gaith, Bentahar Jamal, Wahab Omar, Mizouni Rabeb, Song Alyssa, Cohen Robin, Otrouk Hadi, Mourad Azzam, Cheriton David. A Survey on Explainable Artificial Intelligence for Cybersecurity. – 2023. – 10.48550/arXiv.2303.12942.
11. Назарова О.О. Области применения систем поддержки принятия решений // Экономика России: новые вызовы и перспективы: Сборник научных трудов Института технологий управления ФГБОУ ВО «МИРЭА - Российский технологический университет». – Москва: ООО "Издательство "Спутник+", 2022. – С. 216–226. – EDN OXQNJD.
12. Калязина Е.Г. Искусственный интеллект в системах поддержки принятия решений на примере управления проектами // International Conference GSOM Economy & Management Conference 2024, 01–05 октября 2024 года, 2024. – St. Petersburg: St. Petersburg State University, 2024. – С. 382–392.
13. Симанков В.С. Система поддержки принятия решений интеллектуального ситуационного центра для обеспечения информационной безопасности / В.С. Симанков, Л.И. Саяхова // Поведенческие теории и практика российской науки: Сборник научных статей по итогам международной научно-практической конференции, Санкт-Петербург, 26–27 февраля 2021 года. – Санкт-Петербург: Санкт-Петербургский государственный экономический университет, 2021. – С. 42–45. – EDN YTQVGL.
14. Акимов Н.Н. Информационная система поддержки принятия решений разработчиком для обеспечения компьютерной безопасности систем верхнего уровня атомных электростанций / Н.Н. Акимов, С.П. Харченко, А.Ю. Павлин // Высокие технологии атомной отрасли. Молодежь в инновационном процессе: сборник материалов XV научно-технической конференции молодых специалистов Росатома, Нижний Новгород, 15–16 сентября 2021 года. – Саров: Российский Федеральный ядерный центр - Всероссийский научно-исследовательский институт экспериментальной физики, 2021. – С. 9–14. – DOI 10.53403/9785951505033 9. – EDN BHGHLLA.
15. Современные системы поддержки принятия решений и проблемы использования в них нейронных сетей / Е.И. Воеводина, Ю.М. Гуляева, Д.Е. Варахтин [и др.] // Экономика и управление: проблемы, решения. – 2023. – Т. 2, № 2(134). – С. 69–74. – DOI 10.36871/ek.up.p.r.2023.02.02.008. – EDN WTRBXL.

16. Кириллова А.Д., Вульфин А.М., Васильев В.И., Гузаиров М.Б. Интеллектуальная система поддержки принятия решений при оценке рисков нарушения информационной безопасности АСУ ТП промышленных объектов. Моделирование, оптимизация и информационные технологии. 2023; 11(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1476> DOI: 10.26102/2310-6018/2023.43.4.029

17. Чупакова А.О. Разработка и обучение модели искусственной нейронной сети для создания систем поддержки принятия решений / А.О. Чупакова, С.В. Гудин, Р.Ш. Хабибуллин // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. – 2020. – № 3. – С. 61-73. – DOI 10.24143/2072-9502-2020-3-61-73. – EDN IUVNKB.

18. Баранов В.В. Методические основы поддержки принятия решений при разработке систем защиты объектов информатизации / В.В. Баранов // Информационная безопасность цифровой экономики: Материалы XVIII Всероссийской научно-практической конференции (в рамках IX Пленума регионального отделения Федерального учебно-методического объединения в системе высшего образования по укрупненной группе специальностей и направлений подготовки 10.00.00 «Информационная безопасность» по Сибирскому и Дальневосточному федеральным округам (СибРОУМО)), Хабаровск, 29 июня – 01 2022 года. – Новосибирск: Сибирский государственный университет телекоммуникаций и информатики, 2022. – С. 35-42. – EDN GBPTSU.

19. Kirillova A.D., Vulfin A.M., Vasilyev V.I., Guzairov M.B. Intelligent decision support system for assessing information security risks of ICS. Modeling, Optimization and Information Technology. 2023; 11(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1476> DOI: 10.26102/2310-6018/2023.43.4.029.

20. Чукин А.Ю. Методика оценки защищенности сложной организационно-технической системы с внедрением системы поддержки принятия решения / А.Ю. Чукин, Н.И. Елисеев, И.М. Антоненко // Автоматизация процессов управления. – 2023. – № 1(71). – С. 51-59. – DOI 10.35752/1991-2927_2023_1_71_51. – EDN ODSPNY.

21. Moustafa N., Jill S. UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set) 2015 Military Communications and Information Systems Conference (MilCIS). Canberra, ACT, pp. 1–6, 2015. DOI: 10.1109/MilCIS.2015.7348942

22. Toluwalope Ajayi, James Andrew. Automating Security Operations Centers (SOCs) with AI: Benefits and Challenges. – 2025.

23. Олтсик Дж. Обоснование автоматизации операций безопасности / Джон Олтсик // CSO. – 2022. – 3 нояб. – Режим доступа: <https://www.csoonline.com/article/573997/making-the-case-for-security-operation-automation.html> (дата обращения: 24.11.2025).

References

1. Golikova A.A., Mishina N.A. Cybersecurity Threats in the Context of Digital Business Processes. In Current Issues and Trends in Modern Economics Development, 433–437. Samara: Samara State Technical University, 2024. – P. 433-437. – EDN AHCYAY.

2. Jada Irshaad, Mayayise Thembekele. The impact of artificial intelligence on organisational cyber security: An outcome of a systematic literature review. Data and Information Management. – 2023. – 8(2) – 100063. 10.1016/j.dim.2023.100063.

3. Santos R., Boente A., Ferreira V., Boente R., Luz D., Duarte L., Santos A., Vasconcelos G. Artificial intelligence and cybersecurity: A study of artificial intelligence in cybernetic defense // ARACÊ. – 2025. – No. 7. – P. 23155–23178. – DOI: 10.56238/arev7n5-133.

4. Mohamed N. Artificial intelligence and machine learning in cybersecurity: A deep dive into state-of-the-art techniques and future paradigms // Knowledge and Information Systems. – 2025. – Vol. 67. – No. 6969–7055. – DOI: 10.1007/s10115-025-02429-y.

5. Lysenko S. The Role of Artificial Intelligence in Cybersecurity: Automation of Protection and Detection of Threats. Economic Affairs. 2024. – 69. – 10.46852/0424-2513.1.2024.6.

6. Manoj Nair Meghna, Deshmukh Atharva, Tyagi Amit. Artificial Intelligence for Cyber Security: Current Trends and Future Challenges. – 2023. – 10.1002/9781394213948.ch5.

7. Ozkan Merve, Akin Erdal, Aslan Ömer, Kosunalp Selahattin, Iliev Teodor, Stoyanov Ivaylo. A Comprehensive Survey: Evaluating the Efficiency of Artificial Intelligence and Machine Learning Techniques on Cyber Security Solutions. IEEE Access. PP. – 2024. – 10.1109/ACCESS.2024.3355547.

8. Naik Binny, Mehta Ashir, Yagnik Hiteshri, Shah Manan. The impacts of artificial intelligence techniques in augmentation of cybersecurity: a comprehensive review. Complex & Intelligent Systems. – 2021. – 8. 10.1007/s40747-021-00494-8.

9. Akhtar Muhammad, Feng Tao. An overview of the applications of Artificial Intelligence in Cybersecurity. EAI Endorsed Transactions on Creative Technologies. – 2021. – 172218. 10.4108/eai.23-11-2021.172218.
10. Rjoub Gaith, Bentahar Jamal, Wahab Omar, Mizouni Rabeb, Song Alyssa, Cohen Robin, Otrok Hadi, Mourad Azzam, Cheriton David. A Survey on Explainable Artificial Intelligence for Cybersecurity. – 2023. – 10.48550/arXiv.2303.12942.
11. Nazarova O.O. Applications of Decision Support Systems. In Russia's Economy: New Challenges and Perspectives, 216–226. Moscow: Sputnik+ Publishing, 2022. – P. 216–226. – EDN OXQNJD.
12. Kalyazina E.G. Artificial Intelligence in Decision Support Systems on the Example of Project Management. In International Conference GSOM Economy & Management Conference 2024, October 01–05, 2024. – St. Petersburg: St. Petersburg State University, 2024. – P 382–392.
13. Simankov V.S., Salyakhova L.I. System Supporting Decision-Making in an Intelligent Situational Center for Information Security. In Behavioral Theories and Practices of Russian Science, 42–45. Saint Petersburg: Saint Petersburg State University of Economics, 2021. – P. 42–45. – EDN YTQVGL.
14. Akimov N.N., Kharchenko S.P., Pavlin A.Yu. Information Support System Developer for Ensuring Computer Security of Top-Level Nuclear Power Plant Systems. In High Technologies of the Atomic Industry, 9–14. Nizhny Novgorod: Rosatom, 2021. DOI: 10.53403/9785951505033_9.
15. Voevodina E.I., Gulyaeva Y.M., Varahitin D.E. Modern Decision Support Systems and Challenges of Using Neural Networks. Economics and Management: Problems and Solutions 2 (2023): 69–74. <https://doi.org/10.36871/ek.up.p.r.2023.02.02.008>.
16. Kirillova A.D., Vulfin A.M., Vasilev V.I., Guzeyrov M.B. Intelligent Decision Support System for Risk Assessment of Information Security of Industrial Control Systems. Modeling, Optimization and Information Technologies. – 2023. – 11, no. 4. <https://doi.org/10.26102/2310-6018/2023.43.4.029>.
17. Chupakova A.O., Gudim S.V., Khabibulin R.Sh. Development and Training of an Artificial Neural Network Model for Creating Decision Support Systems. Bulletin of Astrakhan State Technical University, Series Management, Computing and Informatics. – 2020. – 3. – P. 61–73. <https://doi.org/10.24143/2072-9502-2020-3-61-73>.
18. Baranov V.V. Methodological Foundations for Supporting Decision-Making in the Development of Information Security Systems. In Conference Proceedings. Khabarovsk: Siberian State University of Telecommunications and Informatics, 2022, 35–42.
19. Kirillova A.D., Vulfin A.M., Vasilyev V.I., Guzeyrov M.B. Intelligent decision support system for assessing information security risks of ICS. Modeling, Optimization and Information Technology. 2023; 11(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1476> DOI: 10.26102/2310-6018/2023.43.4.029.
20. Chukin A.Yu., Eliseev N.I., Antonenko I.M. Methodology for Assessing the Security of a Complex Organizational-Technical System with the Implementation of a Decision Support System. Automation of Management Processes. 2023. – 1. – P. 51–59. https://doi.org/10.35752/1991-2927_2023_1_71_51.
21. Moustafa N., Jill S. UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set) 2015 Military Communications and Information Systems Conference (MilCIS). Canberra, ACT, pp. 1–6, 2015. DOI: 10.1109/MilCIS.2015.7348942
22. Toluwalope Ajayi, James Andrew. Automating Security Operations Centers (SOCs) with AI: Benefits and Challenges. – 2025.
23. Oltsik J. Making the Case for Security Operation Automation. CSO, November 3, 2022. <https://www.csoononline.com/article/573997/making-the-case-for-security-operation-automation.html>

Чмыхало Данил Сергеевич, магистрант кафедры «Информационная безопасность в вычислительных системах и сетях», ФГБОУ ВО «Донской государственный технический университет» (ДГТУ), г. Ростов-на-Дону, Россия

Газизов Андрей Равильевич, кандидат педагогических наук, доцент, доцент кафедры «Информационная безопасность в вычислительных системах и сетях», ФГБОУ ВО «Донской государственный технический университет» (ДГТУ), г. Ростов-на-Дону, Россия

Легонько Ольга Леонидовна, кандидат технических наук, доцент, доцент кафедры «Информационная безопасность в вычислительных системах и сетях», ФГБОУ ВО «Донской государственный технический университет» (ДГТУ), г. Ростов-на-Дону, Россия

Чмыхало Данил Сергеевич, Master's student of the Department of Information security in computing systems and networks, Don State Technical University, Rostov-on-Don, Russia

Gazizov Andrey Ravilevich, Candidate of Pedagogical Sciences, Associate Professor, Associate Professor of the Department of Information security in computing systems and networks, Don State Technical University, Rostov-on-Don, Russia

Legonko Olga Leonidovna, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Information security in computing systems and networks, Don State Technical University, Rostov-on-Don, Russia

УДК 004.8

DOI: 10.18413/2518-1092-2026-11-2-0-7

Басов О.О.¹
Колесникова А.И.²

ПОДХОДЫ К ВЫЯВЛЕНИЮ АНОМАЛЬНОГО ПОВЕДЕНИЯ ЛЮДЕЙ НА ОСНОВЕ ИЗОБРАЖЕНИЙ С КАМЕР ВИДЕОНАБЛЮДЕНИЯ

¹) Общество с ограниченной ответственностью «СПИЧАП»,
ул Седова, 11к.2, литера А, помещ. 7н-35, часть помещ. 1, г. Санкт-Петербург, 192019, Россия
²) Акционерное общество «АСТ», пер. Капранова, 3, стр. 2, г. Москва, 123242, Россия

e-mail: nastya.wheel@gmail.com

Аннотация

В статье представлен обзор подходов к автоматическому выявлению аномального поведения человека по видеозаписям с камер наблюдения. Актуальность работы обусловлена многообразием несистематизированных подходов к решению задачи детекции аномального поведения, а также наличием нерешённых проблем, сохраняющихся в данной области. Рассматриваются методы, ориентированные на детекцию отклоняющегося поведения людей. Проведена систематизация существующих исследований, выделены основные направления развития области и актуальные проблемы, а также проанализированы преимущества и ограничения рассматриваемых подходов. Отдельное внимание уделено наборам данных, применяемым для решения задачи детекции аномалий поведения человека: обозревается их направленность, количество данных, разметка. В результате исследования установлено, что в области автоматического определения аномалий преобладает тенденция к использованию semi-supervised обучения, тогда как supervised обучение остаётся актуальным для узких областей, где возможно чётко определить случаи аномального поведения.

Ключевые слова: видеонаблюдение; детекция аномального поведения; компьютерное зрение; semi-supervised обучение; наборы данных; систематизация подходов

Для цитирования: Басов О.О., Колесникова А.И. Подходы к выявлению аномального поведения людей на основе изображений с камер видеонаблюдения // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 77-90. DOI: 10.18413/2518-1092-2026-11-2-0-7

Basov O.O.¹
Kolesnikova A.I.²

APPROACHES TO DETECTING ANOMALOUS HUMAN BEHAVIOR BASED ON IMAGES FROM CCTV CAMERAS

¹) Limited Liability Company «SPEECHUP»,
11 Sedova St., Building 2, Litera A, Premises 7N-35, Part of Premises 1, Saint Petersburg, 192019, Russia
²) Joint Stock Company «AST»,
3 Kapranova trans., Building 2, Moscow, 123242, Russia

e-mail: nastya.wheel@gmail.com

Abstract

This paper presents a review of approaches to the automatic detection of anomalous human behavior from surveillance video recordings. The relevance of the study is обусловлена the diversity of existing yet insufficiently systematized approaches to anomaly detection, as well as the presence of unresolved problems that remain in this field. The review focuses on methods aimed at detecting deviant human behavior. Existing studies are systematized, the main directions of the field's development and its current challenges are identified, and the advantages and limitations of the considered approaches are analyzed. Special attention is given to the datasets used for human behavior anomaly detection, including their application focus, data volume, and annotation characteristics. The study shows that semi-supervised learning currently dominates in the VAD

field, whereas supervised learning remains relevant for narrow domains in which anomalous behavior can be clearly defined.

Keywords: video surveillance; anomaly detection; computer vision; semi-supervised learning; datasets; systematization of approaches

For citation: Basov O.O., Kolesnikova A.I. Approaches to Detecting Anomalous Human Behavior Based on Images from CCTV Cameras // Research result. Information technologies. – T.11, №2, 2026. – P. 77-90. DOI: 10.18413/2518-1092-2026-11-2-0-7

ВЕДЕНИЕ

Крайне важным для обеспечения общественной безопасности, в частности, для своевременного реагирования и возможного предотвращения противоправного поведения или несчастных случаев, является определение подозрительной активности в видеопотоках систем видеонаблюдения. Однако повсеместное внедрение и совершенствование таких систем делает невозможным ручной мониторинг наблюдаемых событий и сцен. Автоматизировать процесс контроля за видеопотоками позволяют технологии компьютерного зрения.

Подозрительная активность – достаточно широкое понятие, которое позволяет рассматривать автоматическое определение аномалий (video anomaly detection, VAD) в следующих основных направлениях: 1) аномалии поведения людей, 2) аномалии дорожного движения, 3) аномалии окружающей среды и 4) аномалии инфраструктуры. Настоящее исследование ставит целью рассмотрение методов, позволяющих детектировать подозрительную активность человека, и не обзоревает оставшиеся три направления.

Аномалия – это событие, значительно отклоняющееся от нормального поведения человека. Это отклонение может быть разным в зависимости от контекста и требует рассмотрения разных видов аномального поведения. Для удобства анализа на основе множества классификаций была составлена наиболее полная для VAD классификация видов поведения (Рис.1). Она не раскрывает внутренние виды отклоняющегося поведения, к которым (в зависимости от классификаций) относятся психопатологические типы и ряд аддиктивных типов, которые не могут быть определены визуально.




Рис. 1. Классификация отклоняющегося поведения

Fig. 1. Classification of deviant behavior

В психолого-педагогической литературе отклоняющееся поведение человека принято называть девиантным [2]. Оно трактуется как система поступков или отдельные поступки человека, в зависимости от его возраста, носящие характер отклонения от принятых в обществе норм. Это

определение включает в себя класс нестандартного поведения, которое является правомерным и не рассматривается в области VAD. С точки зрения социологического подхода девиантное поведение является поведение, которое отклоняется от институционализированных ожиданий. Это определение можно расширить до поступков, действий человека или группы лиц, не соответствующих официально установленным (правовым) или фактически сложившимся (обычай, традиции, мораль) в данном обществе нормам и ожиданиям [3]. Такой подход позволяет относить к девиантному поведению и положительное и одобряемое обществом отклоняющееся поведение, такое как героизм, трудоголизм, альтруизм и прочее. Аномальное поведение также может определяться социологами как различные формы негативного поведения лиц, сфера нравственных пороков, отступление от принципов, норм морали и права. Вместе с тем правовой подход окончательно сужает этот круг типов до противоправного поведения, определяя аномальное поведение как поведение, нарушающее существующие в данном обществе общепринятые (в том числе правовые) нормы и являющееся общественно опасным или социально вредным [1].

Анализ толкований позволяет выделить цветом на схеме (Рис.1) актуальные для области VAD виды аномального поведения. Они включают в себя аддиктивное поведение (пребывание в сильном алкогольном и наркотическом опьянении), административные правонарушения, которые могут быть зафиксированы камерами видеонаблюдения, открытые уголовные преступления и ряд скрытых уголовных преступлений, к которым относятся кражи. Помимо названных проявлений отклоняющегося поведения, цветом на схеме обозначена детекция патологических, или болезненных, состояний, которые включают в себя падения, эпилептические приступы и прочие внешние проявления потери человеком контроля над своим состоянием. Такой тип поведения некорректно относить к отклоняющемуся по причине отсутствия принятия решения со стороны человека о его начале; патологическое состояние начинается непроизвольно. Детекция патологических состояний полезно в медицинской сфере и также изучается областью автоматического определения аномального поведения.

Широкий спектр детектируемых видов поведения сопряжён с внушительным рядом проблем. Рассмотрим их подробнее.

А. Открытый характер аномалий

П1. Зависимость от контекста. Аномальность поведения сильно зависит от контекста, что требует определения понимания перечня аномальных и нормальных действий на момент постановки задачи. Даже если задача чётко сформулирована и перечень аномальных действий известен, невозможно показать модели все возможные аномалии на этапе обучения, поскольку аномалией является любое отклонение от нормы, включая события, которых никогда не было раньше.

П2. Изменение нормы. Обученная модель не сможет адаптироваться к сдвигу нормы, который возможен как с корректировкой постановки задачи (введение новых правил в области эксплуатации или их аннулирование), так и с косвенным изменением паттернов поведения людей. Это требует дообучения модели.

Б. Проблемы данных

П3. Данные для обучения. Аномалии по определению являются редким событием, поэтому неизбежно возникают трудности со сбором достаточного для обучения негативных примеров. Дополнительной проблемой является сложность разметки таких данных ввиду своей трудозатратности и неоднозначности определения аномалии.

В. Использование пространственно-временных характеристик

П4. Вариативность окружающей среды. Если модель работает на уровне пикселей, это делает её чувствительной к изменениям освещения и фона. Может возникать и обратный эффект, когда информация в кадре избыточна, что может мешать модели улавливать паттерны при обучении. При этом некоторые задачи нуждаются в детальной визуальной информации и не позволяют ограничиться pose-based методами.

П5. Временные паттерны. Аномалии представляют собой нерегулярные вариативные по продолжительности движения. Определение сложной подозрительной активности достигается через анализ длинной последовательности, что затрудняет реакцию на кратковременные резкие аномалии.

П6. Аномалии на уровне группы. Некоторые аномалии включают в себя взаимодействие нескольких человек или толпы, для их обнаружения требуется моделирование коллективного поведения. Последнее также приводит к проблеме установления инициатора аномалии, а не вынесения решения для всего кадра. Также существует проблема сложной динамики, окклюзий и аномалий толпы, когда действия людей по отдельности не являются аномальными.

Г. Проблемы оценки

П7. Оценка качества. Ввиду специфики данных (аномалия – редкое событие) классов для оценки качества модели ограниченное количество, как и примеров в них. Оценка может быть неточной ещё и потому, что может провалиться в детекции при появлении нового типа аномалий при высоком качестве на тестовых данных. Определение качества также затруднено отсутствием метрики, в достаточной мере учитывающей специфику VAD.

Д. Проблемы эксплуатации

П8. Устойчивость и обобщаемость. В зависимости от обучающих данных модели могут быть чувствительны как к визуальному шуму, так и к изменению положению камеры, масштабу и частоте следования видеок кадров. Последние критерии актуальны и для pose-based методов, которые не используют пиксели.

П9. Калибровка. При использовании модели необходимо выбрать чувствительность модели, пожертвовав либо точностью, либо полнотой, когда оба из критериев могут быть крайне важны при эксплуатации: FN (false negative, или ложно отрицательные) случаи обесценивают работу системы, а FP (false positive, или ложно положительные) снижают внимание к срабатываниям при ручном контроле.

П10. Катастрофическое забывание. Проблема П1 обращает внимание на важность дообучения модели со временем, что поднимает проблему компромисса между сохранением существующих знаний и приобретением новых без взаимного ущерба, так как при дообучении на новых данных могут быть потеряны старые знания.

П11. Использование в режиме реального времени. Архитектура модели должна быть достаточно лёгкой, чтобы обрабатывать необходимый объём данных без задержки. Pose-based методы в свою очередь требуют дополнительного использования вспомогательных моделей для обнаружения людей, их отслеживания и поиска ключевых точек, что также создаёт трудности при эксплуатации.

Активное развитие области автоматического определения аномального поведения требует систематизации полученных результатов и созданных датасетов, анализа опробованных подходов и выделения дальнейших направлений совершенствования VAD.

Работа состоит из 4 частей. Часть 1 посвящена краткому обзору истории развития VAD для отслеживания тенденций развития области и освещения основных методов. Часть 2 представляет обзор подходов к детектированию определённых выше типов аномального поведения. В части 3 описаны актуальные датасеты и их содержание. Часть 4 подводит итоги работы и представляет дальнейшие направления исследования.

1. ИСТОРИЧЕСКАЯ СПРАВКА

Развитие методов VAD в современном виде начинается с работ начала 2010-х годов и несколько разных траекторий исследования. В работе Anomaly Detection in Crowded Scenes (2010) [27] нормальность сцены моделировалась через совместное описание внешнего вида и динамики локальных участков видео, тогда как в Sparse Reconstruction Cost for Abnormal Event Detection (2011) [13] аномалия определялась по тому, насколько хорошо наблюдение разлагается по словарю

нормальных паттернов. Параллельно с развитием методов формировались и первые наборы данных, многие из которых актуальны и на текущий момент: датасеты UCSD Ped1/Ped2 [24], CUHK Avenue [26] и позднее ShanghaiTech Campus [25] постепенно усложняли постановку задачи, переходя от обнаружения нетипичных объектов в сцене к более разнообразным и реалистичным сценариям аномального поведения.




Рис. 2. Обобщённая схема методов VAD
Fig. 2. Generalized diagram of VAD methods

Следующий этап был связан с переходом к глубоким моделям и дальнейшим расширением самих подходов. В работе Learning Temporal Regularity in Video Sequences (2016) [20] был предложен автоэнкодерный reconstruction-based подход, выявляющий аномалию по ошибке реконструкции нормальной динамики, а в Future Frame Prediction for Anomaly Detection (2018) [25] эта логика была развита в prediction-based направлении, где отклонение фиксируется уже через ошибку предсказания будущего кадра. В том же 2018 году работа Real-World Anomaly Detection in Surveillance Videos [40] с датасетом UCF-Crime существенно расширила обучающую постановку, введя weakly supervised подход на основе video-level меток и multiple instance learning. В дальнейшем область стала смещаться от анализа сцены целиком к более семантически насыщенным object-centric стратегиям, в которых рассматриваются отдельные объекты, прежде всего люди, и их поведение.

К началу 2020-х годов область автоматического определения аномального поведения представляла собой совокупность различных направлений – от статистических до

реконструирующих, предсказательных, weakly supervised и объектно-ориентированных моделей. Общий пайплайн обработки видео в VAD методов отражён на Рисунке 2. Он систематизирует основные компоненты задачи – типы входных данных, используемые архитектуры и виды обучения.

II. ОБЗОР МЕТОДОВ

1. Общая направленность

Для устранения проблемы сбора и разметки данных (проблема ПЗ) в области VAD остаётся популярным решение задачи через *semi-supervised*, или полуконтролируемое, обучение. При таком подходе в обучающей выборке присутствуют только наблюдения положительного класса, и модель изучает распределение нормального поведения. На этапе инференса наблюдения, которые плохо объясняются этим распределением, классифицируются моделью как аномалия.

В качестве примера была рассмотрена и исследована модель COSKAD [19]. Её авторы ставят целью выявление любого поведения, отклоняющегося от нормы, поэтому модель обучается на нормальных *скелетных представлениях*. Фиксированные последовательности человеческого движения кодируются в виде пространственно-временных скелетных графов [39] и проецируются в латентное пространство. В статье предложено три варианта пространства: 1) евклидово, 2) сферическое и 3) гиперболическое. Функция обучения модели выглядит следующим образом:

$$\min_{\mathcal{W}} \frac{1}{N} \sum_{i=1}^N d(\Phi(x_i, \mathcal{W}), c) + \alpha f(\mathcal{W}),$$

где x_i - i -ая последовательность движений фиксированной длины, c – центр, вокруг которого модель старается собрать нормальные образцы, $\Phi(x_i, \mathcal{W})$ - отображение этого образца в латентное пространство, полученное с помощью COSKAD, $d(\cdot, \cdot)$ – расстояние в выбранном латентном пространстве, $f(\mathcal{W})$ – регуляризатор весов. Таким образом модель учится проецировать полученные эмбединги в латентное пространство и обучается “сжимать” нормальные образцы в узкую область вокруг центра.

Для экспериментального подтверждения эффективности архитектуры модель была обучена в конфигурации евклидового латентного пространства, которая показала наилучшие результаты в оригинальной статье. Результаты подтвердили эффективность модели COSKAD на реальных данных, их выборочная демонстрация приведена на Рисунке 3.



Рис. 3. Инференс COSKAD на реальных данных: а) драка, б) драка, в) танец
Fig. 3. COSKAD inference on real data: a) fight, b) fight, c) dance

Несмотря на свою эффективность, COSKAD и другие схожие модели [28] сталкиваются с рядом ограничений. Так, модель классифицирует ряд нормальных для общества действия как аномальное событие (см. Рисунок 3, в). Это отсылает к проблеме контекстности аномальности поведения (проблема П1), которую *semi-supervised* модели не могут решить в полной мере ввиду

отсутствия возможности показать при обучении аномальные примеры. Полуконтролируемый подход обучения не позволяет включить положительно-ложные срабатывания в обучающую выборку, если их недостаточно или если они похожи на требуемые к детекции типы девиантного поведения. Отдельным ограничением является фиксированная при обучении длина последовательности (проблема П5).

Благодаря графовой нейронной сети внутри сама COSKAD работает с достаточной производительностью, но, как и все *skeleton-based* подходы, требует использования детектора, трекера и модели поиска ключевых точек (проблема П11). Это делает её напрямую зависимой от качества работы предшествующих моделей и замедляет скорость обработки видеопотока.

Эти методы могут детектировать отдельные типы поведения, представленные на Рисунке 1. Так, в наборе данных UBnormal [4], который среди прочих использовали авторы COSKAD, представлены примеры патологических состояний. Однако ввиду своей направленности общие методы не всегда показывают свою эффективность на специфических аномалиях и не всегда могут быть использованы из-за невозможности сильно урезать круг аномальных событий.

2. Отклоняющееся поведение

В рассматриваемом классе задач распространёнными остаются *пиксельные* методы, так как позволяют учитывать мелкие детали сцены и внешний вид объектов. Так, методы [22; 30] предлагают использовать *pixel-based* подход для определения кражи. На их фоне выделяются работы [29] и [12], которые предлагают детектировать не сам момент кражи, а подозрительное поведение человека. Используя *supervised* обучение, такие подходы неизбежно сталкиваются с проблемами ограниченности данных для обучения, проблемой дисбаланса классов и чувствительностью к шуму (проблемы П3-П4, П8). В противовес им для детекции краж предлагаются и знакомые нам *posed-based*, или *skeleton-based*, методы [36] и [38]. Имея преимущество с точки зрения анонимизированности используемых данных, эти методы сталкиваются с проблемой зависимости от качества работы предшествующих моделей (проблема П11).

Предлагаются решения и для других категорий противоправного поведения. Так, для обнаружения **вооружённого ограбления** предлагаются методы, завязанные на детекции оружия. Если [7] предлагает обособленную детекцию, то [38] учитывает ключевые точки человека, а [18] после определения оружия обрабатывает изображение с помощью свёрточной нейронной сети, что повышает надёжность и применимость методов. Существуют методы определения **вандализма** [33], **физического насилия** с использованием информации кадра [14] и поз [31], **сексуальных домогательств** [21] и **применения насилия к женщинам** [6].

3. Патологические состояния

Область VAD предлагает решения для определения болезненных состояний, когда человеку необходима сторонняя помощь. Ранние подходы в выявлении **падений** человека использовали *пиксельные методы* [43], но с развитием методов перешли к использованию *скелетных представлений* [34] и *смешанных подходов* [9]. Вместе с попыткой уменьшить вычислительную нагрузку в исследовании [32] также пробуют работать напрямую с RGB-кадром более совершенными методами. Помимо определения падений существуют решения для определения эпилептических припадков [10; 44; 35], болезни Паркинсона [41; 23].

В отличие от сферы общественной безопасности, где преобладают варианты *semi-supervised* обучения, для сферы детекции болезненных состояний значительно чаще используется *supervised* подход. Это ставит решение в большую зависимость от узкоспециализированных датасетов (проблема П3). Тем не менее, в подобных задачах круг аномалий и нормы практически не меняется (проблемы П1 и П2 отсутствуют), и архитектура, жертвуя своей универсальностью, позволяют гарантировать большую надёжность детекции.

III. ОБЗОР ДАТАСЕТОВ

Все рассмотренные ранее методы VAD в значительной степени опираются на общедоступные датасеты, которые используются для обучения, тестирования и оценки предлагаемых моделей. Для удобства их использования помимо текстового описания оформлена сводная таблица (Табл. 1) с характеристиками датасетов, годом публикации, указанием заявленной разметки.

A. UCSD Ped1 и Ped2. Набор данных собран стационарной камерой на территории кампуса. Нормальный паттерн в нём задаётся движением только пешеходов, тогда как аномалии связаны либо с появлением непешеходных объектов, либо с нетипичными траекториями движения людей. Датасет разделён на две сцены: Ped1 содержит клипы размером 158x238 пикселей, в этих сценах люди движутся в направлении к камере и от камеры, Ped2 имеет более высокое разрешение 240x360 пикселей, где большинство пешеходов движется параллельно камере.

B. CUHK Avenue представляет собой датасет из 15 видеопоследовательностей с человеческой активностью. Он ориентирован на выявление нетипичного поведения в обычной уличной среде, где аномалии представлены такими событиями, как бег, бесцельное пребывание в зоне наблюдения и бросание предметов.

B. ShanghaiTech Campus охватывает 13 различных сцен. В отличие от более ранних небольших наборов данных, он ориентирован на более сложные сценарии, поскольку включает большое число обучающих и тестовых видеопоследовательностей, а также несколько типов аномальных событий.

Г. UCF-Crime и HR-Crime. В отличие от ранних VAD-датасетов, он построен на реальных, а не постановочных сценах и охватывает широкий спектр опасных и криминальных инцидентов в разнообразных условиях наблюдения. Набор данных включает 13 типов аномалий: Abuse, Arrest, Arson, Assault, Accident, Burglary, Explosion, Fighting, Robbery, Shooting, Stealing, Shoplifting и Vandalism. HR-Crime – это подмножество UCF-Crime, специально отфильтрованное так, чтобы в аномалии ключевую роль играло поведение человека; из него исключались события, не связанные с человеком, сцены без чёткого обзора людей, большие толпы и слишком длинные видео.

Д. UBI-Fights и XD-Violence. Оба набора данных позволяют решать задачу детектирования насилия. UBI-Fights – узкий датасет, направленный на автоматическое определение драк. XD-Violence заметно шире: он ориентирован на детекцию насилия в общем смысле и включает шесть типов событий – Abuse, Car Accident, Explosion, Fighting, Riot и Shooting.

Е. VFP290K – специализированный датасет для визуального обнаружения лежащего или упавшего человека. В отличие от общих VAD-датасетов, здесь целевое событие заранее фиксировано: модель должна различать упавшего и неупавшего человека на уровне детекции объектов.

Ж. UBnormal представляет собой 29 виртуальных сцен, сгенерированных на основе реальных фоновых изображений и анимированных 3D-персонажей и объектов. В отличие от классических VAD-датасетов, он включает аномальные события в обучающую выборку, но при этом сохраняет отдельные наборы типов аномалий в обучении и тесте.

З. CamNuvem. Этот набор данных предназначен для выявления ограблений. Он включает 972 видео, из которых 486 содержат сцены ограблений, собранные из открытых источников, а ещё 486 нормальных видео заимствованы из UCF-Crime для формирования сбалансированного набора. Датасет отражает вариативность реальных условий наблюдения – различия в точках обзора, композиции сцены и признаках ограбления.

И. NWPU Campus включает 28 классов аномальных событий в 43 сценах с участием пешеходов и транспорта. В отличие от более ранних наборов данных, он охватывает широкий спектр нормальных и аномальных событий, включая контекстные аномалии, где интерпретация события зависит от условий.

К. CHAD. Это набор данных ограничен одной сценой, запись которой ведётся с четырёх разных камер видеонаблюдения. CHAD включает в себя 22 класса аномального поведения, в том числе драки, воровство, обмороки/падения, погоню, выбрасывание мусора, бег. В отличие от

многих ранних VAD-датасетов, он ориентирован на анализ поведения человека и помимо покадровых меток содержит подробные аннотации людей – ограничивающие рамки, идентификаторы и ключевые точки позы.

Л. PoseLift. Это специализированный датасет для детекции магазинных краж, состоящий из 43 видео с кражами и 112 – с обычным шопингом. Его особенность заключается в нераспространении исходных пиксельных видео, из-за чего набор данных предоставляет из себя последовательности поз, ограничивающие рамки и идентификаторы людей, собранным по реальным записям розничного магазина.

IV. ВЫВОДЫ

Представленная работа систематизирует используемые в области автоматического детектирования аномального поведения человека подходы и данные. Комплексный обзор позволяет говорить о преобладании semi-supervised методов в области общественной безопасности и supervised обучения в сфере специфических аномалий, свойственных, например, медицине. Эта тенденция отражается и в адаптированности многих наборов данных под semi-supervised обучение путём формирования обучающей выборки из нормальных наблюдений.

Дальнейшие исследования предполагается направить на применение исследованных методов для решения конкретных практических задач выявления аномального поведения людей, в частности, автоматической детекции административных правонарушений на изображениях с камер городского видеонаблюдения.

Таблица

Сводная таблица датасетов VAD

Table

Summary table of VAD datasets

Название	Направленность	Год	Длительность	Разметка	Источник
UCSD Ped1	Общая	2010	5 минут	покадровые бинарные метки; пиксельные маски для части тестовых данных	[24]
UCSD Ped2	Общая		5 минут		
CUHK Avenue	Общая	2013	30 минут	покадровые бинарные метки и bounding box	[26]
ShanghaiTech Campus	Общая	2018	3,5 часа	покадровые бинарные метки; пиксельные маски для тестовых данных	[25]
UCF-Crime	Общая	2018	128 часов	бинарные метки на уровне видео для обучающих данных; временные аннотации тестовых данных	[40]
HR-Crime	Общая	2021			[8]
UBI-Fights	Драки	2020	80 часов	покадровые бинарные метки	[17]
XD-Violence	Насилие	2020	217 часов	бинарные метки и класс на уровне видео; временные аннотации для тестовых данных	[42]
VFP290K	Падение людей	2021	294713 кадров	bounding box, бинарные метки для них	[5]
UBnormal	Общая	2022	132 минуты	пиксельные маски (для всех данных)	[4]
CamNuvem	Ограбления	2022	57 часов	бинарные метки на уровне видео; покадровые метки для тестовых данных	[16]

NWPU Campus	Общая	2023	16 часов	бинарные метки на уровне видео; временные аннотации для тестовых данных	[11]
CHAD	Общая	2023	10,5 часов	покадровые метки, bounding box, ключевые точки позы	[15]
PoseLift	Кражи	2025	63 минуты	покадровые метки, bounding box, ключевые точки позы	[37]

Список литературы

1. Девиантное поведение // Энциклопедия права, 2015 г. URL: https://encyclopediya_prava.academic.ru/1486/%D0%94%D0%B5%D0%B2%D0%B8%D0%B0%D0%BD%D1%82%D0%BD%D0%BE%D0%B5_%D0%BF%D0%BE%D0%B2%D0%B5%D0%B4%D0%B5%D0%BD%D0%B8%D0%B5 (дата обращения: 29.03.2026).
2. Мардахаев Л.В. Социальная педагогика: учебник. М.: Гардарики, 2005. 269 с.
3. Отклоняющееся поведение // Большая российская энциклопедия, 2022 г. URL: <https://bigenc.ru/c/otkloniashcheesia-povedenie-b3ad70> (дата обращения: 29.03.2026).
4. UBnormal: New Benchmark for Supervised Open-Set Video Anomaly Detection / Acsintoae A., Florescu A., Georgescu M.-I., Mare T., Sumedrea P., Ionescu R. T., Khan F. S., Shah M. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 20143–20153.
5. VFP290K: A Large-Scale Benchmark Dataset for Vision-based Fallen Person Detection / An J., Kim J., Lee H., Kim J., Kang J., Shin S., Kim M., Hong D., Woo S.S. // NeurIPS 2021 Datasets and Benchmarks Track. 2021.
6. SUSAN: A Deep Learning-Based Architecture for Violence Detection Against Women in Surveillance Videos / Andrade J.P.F., Si T., Cavalcanti A.P., Nascimento A.C.A., Miranda P.B.C. // Expert Systems with Applications. 2025. Vol. 280. Art. 127337. DOI: 10.1016/j.eswa.2025.127337.
7. Weapon Detection in Real-Time CCTV Videos Using Deep Learning / Bhatti M.T., Khan M.G., Aslam M., Fiaz M.J. // IEEE Access. 2021. DOI: 10.1109/ACCESS.2021.3059170.
8. HR-Crime: Human-Related Anomaly Detection in Surveillance Videos / Boekhoudt K., Matei A., Aghaei M., Talavera E. // Computer Analysis of Images and Patterns. CAIP 2021. Lecture Notes in Computer Science. 2021. P. 164–174. DOI: 10.1007/978-3-030-89131-2_15.
9. Khraief C., Benzarti F., Amiri H. Elderly Fall Detection Based on Multi-Stream Deep Convolutional Networks // Multimedia Tools and Applications. 2020. Vol. 79. P. 19537–19560. DOI: 10.1007/s11042-020-08812-x.
10. Convolutional Neural Network-Based Fast Seizure Detection from Video Electroencephalograms / Chou C.-H., Shen T.-W., Tung H., Hsieh P.F., Kuo C.-E., Chen T.-M., Yang C.-W. // Biomedical Signal Processing and Control. 2023. Vol. 80. Art. 104380. DOI: 10.1016/j.bspc.2022.104380.
11. A New Comprehensive Benchmark for Semi-Supervised Video Anomaly Detection and Anticipation / Cao C., Lu Y., Wang P., Zhang Y. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2023. P. 20392–20401. DOI: 10.1109/CVPR52729.2023.01953.
12. Chinthulla A. Deep Learning-Based Detection of Shoplifting Behavior: Using 3DCNN and LRCN: Masters thesis. Dublin: National College of Ireland, 2025.
13. Cong Y., Yuan J., Liu J. Sparse Reconstruction Cost for Abnormal Event Detection // 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2011. P. 3449–3456. DOI: 10.1109/CVPR.2011.5995434.
14. Combining a Mobile Deep Neural Network and a Recurrent Layer for Violence Detection in Videos / Contardo P., Tomassini S., Falcionelli N., Dragoni A.F., Sernani P. // Proceedings of the RTA-CSIT 2023: 5th International Conference on Recent Trends and Applications in Computer Science and Information Technology. 2023. P. 35-43.
15. CHAD: Charlotte Anomaly Dataset / Danesh Pazho A., Alinezhad Noghre G., Rahimi Ardabili B., Neff C., Tabkhi H. // Image Analysis. SCIA 2023. Lecture Notes in Computer Science. 2023. P. 50–66. DOI: 10.1007/978-3-031-31435-3_4.
16. de Paula D.D., Salvadeo D.H.P., de Araujo D.M.N. CamNuvem: A Robbery Dataset for Video Anomaly Detection // Sensors. 2022. Vol. 22. No. 24. Art. 10016. DOI: 10.3390/s222410016.
17. Degardin B., Proença H. Iterative Weak/Self-Supervised Classification Framework for Abnormal Events Detection // Pattern Recognition Letters. 2021. Vol. 145. P. 50–57. DOI: 10.1016/j.patrec.2021.01.031.

18. Fernandez-Testa S., Salcedo E. Distributed Intelligent Video Surveillance for Early Armed Robbery Detection Based on Deep Learning // 2024 37th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). 2024. DOI: 10.1109/SIBGRAPI62404.2024.10716299.
19. Contracting Skeletal Kinematics for Human-Related Video Anomaly Detection / Flaborea A., D'Amely di Melendugno G.M., D'Arrigo S., Sterpa M.A., Sampieri A., Galasso F. // Pattern Recognition. 2024. Vol. 156. Art. 110817. DOI: 10.1016/j.patcog.2024.110817.
20. Hasan M., Choi J., Neumann J., Roy-Chowdhury A.K., Davis L.S. Learning Temporal Regularity in Video Sequences // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 733-742
21. A Deep Spatio-Temporal Network for Vision-Based Sexual Harassment Detection / Islam M.S., Hasan M.M., Abdullah S., Akbar J.U.M., Arafat N., Murad S. // Proceedings of the 2021 Emerging Technology in Computing, Communication and Electronics (ETCCE). 2021. P. 1–6.
22. Kirichenko L., Radivilova T., Sydorenko B., Yakovlev S. Detection of Shoplifting on Video Using a Hybrid Network // Computation. 2022. Vol. 10. No. 11. Art. 199. DOI: 10.3390/computation10110199.
23. Video-Based Detection of Freezing of Gait in Daily Clinical Practice in Patients With Parkinsonism / Kondo Y., Bando K., Suzuki I., Miyazaki Y., Nishida D., Hara T., Kadone H., Suzuki K. // IEEE Transactions on Neural Systems and Rehabilitation Engineering. 2024. Vol. 32. P. 2250–2260. DOI: 10.1109/TNSRE.2024.3413055.
24. Li W., Mahadevan V., Vasconcelos N. Anomaly Detection and Localization in Crowded Scenes // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2014. Vol. 36. No. 1. P. 18–32. DOI: 10.1109/TPAMI.2013.111.
25. Liu W., Luo W., Lian D., Gao S. Future Frame Prediction for Anomaly Detection – A New Baseline // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 6536–6545. DOI: 10.1109/CVPR.2018.00684.
26. Lu C., Shi J., Jia J. Abnormal Event Detection at 150 FPS in MATLAB // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2013. P. 2720–2727. DOI: 10.1109/ICCV.2013.338.
27. Mahadevan V., Li W., Bhalodia V., Vasconcelos N. Anomaly Detection in Crowded Scenes // 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR). 2010. P. 1975–1981.
28. Graph Embedded Pose Clustering for Anomaly Detection / Markovitz A., Sharir G., Friedman I., Zelnik-Manor L., Avidan S. // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. DOI: 10.1109/CVPR42600.2020.01055.
29. Criminal Intention Detection at Early Stages of Shoplifting Cases by Using 3D Convolutional Neural Networks / Martínez-Mascorro G.A., Abreu-Pederzini J.R., Ortiz-Bayliss J.C., Garcia-Collantes A., Terashima-Marín H. // Computation. 2021. Vol. 9. No. 2. Art. 24. DOI: 10.3390/computation9020024.
30. Shoplifting Detection Using Hybrid Neural Network CNN-BiLSMT and Development of Benchmark Dataset / Muneer I., Saddique M., Habib Z., Mohamed H.G. // Applied Sciences. 2023. Vol. 13. No. 14. Art. 8341. DOI: 10.3390/app13148341.
31. Detecting School Violence Using Artificial Intelligence to Interpret Surveillance Video Sequences / Narynov S., Zhumanov Z., Gumar A., Khassanova M., Omarov B. // Advances in Computational Collective Intelligence. ICCCI 2021. 2021. P. 401–412. DOI: 10.1007/978-3-030-88113-9_32.
32. Núñez-Marcos A., Arganda-Carreras I. Transformer-Based Fall Detection in Videos // Engineering Applications of Artificial Intelligence. 2024. Vol. 132. Art. 107937. DOI: 10.1016/j.engappai.2024.107937.
33. Nyajowi T., Oyie N.O., Ahuna M. CNN Real-Time Detection of Vandalism Using a Hybrid-LSTM Deep Learning Neural Networks // 2021 IEEE AFRICON. 2021. P. 1–6. DOI: 10.1109/AFRICON51333.2021.9570902.
34. Keskes O., Noumeir R. Vision-Based Fall Detection Using ST-GCN // IEEE Access. 2021. Vol. 9. P. 28224–28236. DOI: 10.1109/ACCESS.2021.3058219.
35. Automated Analysis and Detection of Epileptic Seizures in Video Recordings Using Artificial Intelligence / Rai P., Knight A., Hiillos M., Kertész C., Morales E., Terney D., Larsen S. A., Østerkjerhuus T., Peltola J., Beniczky S. // Frontiers in Neuroinformatics. 2024. Vol. 18. Art. 1324981. DOI: 10.3389/fninf.2024.1324981.
36. Shopformer: Transformer-Based Framework for Detecting Shoplifting via Human Pose / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Rahimi Ardabili B., Tabkhi H. // 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). 2025. P. 5752–5761. DOI: 10.1109/CVPRW67362.2025.00574.
37. Exploring Pose-Based Anomaly Detection for Retail Security: A Real-World Shoplifting Dataset and Benchmark / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Yao S., Tabkhi H. // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW). 2025.

38. Salido J., Lomas V., Ruiz-Santaquiteria J., Deniz O. Automatic Handgun Detection with Deep Learning in Video Surveillance Images // Applied Sciences. 2021. Vol. 11. No. 13. Art. 6085. DOI: 10.3390/app11136085.
39. Sofianos T., Sampieri A., Franco L., Galasso F. Space-Time-Separable Graph Convolutional Network for Pose Forecasting // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021. P. 11189–11198. DOI: 10.1109/ICCV48922.2021.01102.
40. Sultani W., Chen C., Shah M. Real-World Anomaly Detection in Surveillance Videos // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 6479–6488.
41. Connie T., Aderinola T. B., Ong T. S., Goh M. K. O., Erfianto B., Purnama B. Pose-Based Gait Analysis for Diagnosis of Parkinson's Disease // Algorithms. 2022. Vol. 15. No. 12. Art. 474. DOI: 10.3390/a15120474.
42. Not Only Look, but Also Listen: Learning Multimodal Violence Detection under Weak Supervision / Wu P., Liu J., Shi Y., Sun Y., Shao F., Wu Z., Yang Z. // Computer Vision – ECCV 2020. 2020. DOI: 10.1007/978-3-030-58577-8_20.
43. Cai X., Li S., Liu X., Han G. Vision-Based Fall Detection With Multi-Task Hourglass Convolutional Auto-Encoder // IEEE Access. 2020. Vol. 8. P. 44493–44502. DOI: 10.1109/ACCESS.2020.2978249.
44. Towards Surveillance Video-and-Language Understanding: New Dataset, Baselines, and Challenges / Yuan T., Zhang X., Liu K., Liu B., Chen C., Jin J., Jiao Z. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2024. P. 22052–22061. DOI: 10.1109/CVPR52733.2024.02082.

References

1. Deviant Behavior. Entsiklopediya prava, 2015. URL: https://encyclopediya_prava.academic.ru/1486/%D0%94%D0%B5%D0%B2%D0%B8%D0%B0%D0%BD%D1%82%D0%BD%D0%BE%D0%B5_%D0%BF%D0%BE%D0%B2%D0%B5%D0%B4%D0%B5%D0%BD%D0%B8%D0%B5 (accessed: 29.03.2026).
2. Mardakhaev L.V. Social Pedagogy. Moscow: Gardariki, 2005. 269 p.
3. Deviant Behavior. Bol'shaya rossiyskaya entsiklopediya, 2022. URL: <https://bigenc.ru/c/otkloniaiushcheesia-povedenie-b3ad70> (accessed: 29.03.2026).
4. UBnormal: New Benchmark for Supervised Open-Set Video Anomaly Detection / Acintoae A., Florescu A., Georgescu M.-I., Mare T., Sumedrea P., Ionescu R. T., Khan F. S., Shah M. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 20143–20153.
5. VFP290K: A Large-Scale Benchmark Dataset for Vision-based Fallen Person Detection / An J., Kim J., Lee H., Kim J., Kang J., Shin S., Kim M., Hong D., Woo S.S. // NeurIPS 2021 Datasets and Benchmarks Track. 2021.
6. SUSAN: A Deep Learning-Based Architecture for Violence Detection Against Women in Surveillance Videos / Andrade J.P.F., Si T., Cavalcanti A.P., Nascimento A.C.A., Miranda P.B.C. // Expert Systems with Applications. 2025. Vol. 280. Art. 127337. DOI: 10.1016/j.eswa.2025.127337.
7. Weapon Detection in Real-Time CCTV Videos Using Deep Learning / Bhatti M.T., Khan M.G., Aslam M., Fiaz M.J. // IEEE Access. 2021. DOI: 10.1109/ACCESS.2021.3059170.
8. HR-Crime: Human-Related Anomaly Detection in Surveillance Videos / Boekhoudt K., Matei A., Aghaei M., Talavera E. // Computer Analysis of Images and Patterns. CAIP 2021. Lecture Notes in Computer Science. 2021. P. 164–174. DOI: 10.1007/978-3-030-89131-2_15.
9. Khraief C., Benzarti F., Amiri H. Elderly Fall Detection Based on Multi-Stream Deep Convolutional Networks // Multimedia Tools and Applications. 2020. Vol. 79. P. 19537–19560. DOI: 10.1007/s11042-020-08812-x.
10. Convolutional Neural Network-Based Fast Seizure Detection from Video Electroencephalograms / Chou C.-H., Shen T.-W., Tung H., Hsieh P.F., Kuo C.-E., Chen T.-M., Yang C.-W. // Biomedical Signal Processing and Control. 2023. Vol. 80. Art. 104380. DOI: 10.1016/j.bspc.2022.104380.
11. A New Comprehensive Benchmark for Semi-Supervised Video Anomaly Detection and Anticipation / Cao C., Lu Y., Wang P., Zhang Y. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2023. P. 20392–20401. DOI: 10.1109/CVPR52729.2023.01953.
12. Chinthulla A. Deep Learning-Based Detection of Shoplifting Behavior: Using 3DCNN and LRCN: Masters thesis. Dublin: National College of Ireland, 2025.
13. Cong Y., Yuan J., Liu J. Sparse Reconstruction Cost for Abnormal Event Detection // 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2011. P. 3449–3456. DOI: 10.1109/CVPR.2011.5995434.
14. Combining a Mobile Deep Neural Network and a Recurrent Layer for Violence Detection in Videos / Contardo P., Tomassini S., Falcionelli N., Dragoni A.F., Sernani P. // Proceedings of the RTA-CSIT 2023: 5th

International Conference on Recent Trends and Applications in Computer Science and Information Technology. 2023. P. 35-43.

15. CHAD: Charlotte Anomaly Dataset / Danesh Pazho A., Alinezhad Noghre G., Rahimi Ardabili B., Neff C., Tabkhi H. // Image Analysis. SCIA 2023. Lecture Notes in Computer Science. 2023. P. 50–66. DOI: 10.1007/978-3-031-31435-3_4.

16. de Paula D.D., Salvadeo D.H.P., de Araujo D.M.N. CamNuvem: A Robbery Dataset for Video Anomaly Detection // Sensors. 2022. Vol. 22. No. 24. Art. 10016. DOI: 10.3390/s222410016.

17. Degardin B., Proença H. Iterative Weak/Self-Supervised Classification Framework for Abnormal Events Detection // Pattern Recognition Letters. 2021. Vol. 145. P. 50–57. DOI: 10.1016/j.patrec.2021.01.031.

18. Fernandez-Testa S., Salcedo E. Distributed Intelligent Video Surveillance for Early Armed Robbery Detection Based on Deep Learning // 2024 37th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). 2024. DOI: 10.1109/SIBGRAPI62404.2024.10716299.

19. Contracting Skeletal Kinematics for Human-Related Video Anomaly Detection / Flaborea A., D'Amely di Melendugno G.M., D'Arrigo S., Sterpa M.A., Sampieri A., Galasso F. // Pattern Recognition. 2024. Vol. 156. Art. 110817. DOI: 10.1016/j.patcog.2024.110817.

20. Hasan M., Choi J., Neumann J., Roy-Chowdhury A.K., Davis L.S. Learning Temporal Regularity in Video Sequences // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 733-742

21. A Deep Spatio-Temporal Network for Vision-Based Sexual Harassment Detection / Islam M.S., Hasan M.M., Abdullah S., Akbar J.U.M., Arafat N., Murad S. // Proceedings of the 2021 Emerging Technology in Computing, Communication and Electronics (ETCCE). 2021. P. 1–6.

22. Kirichenko L., Radivilova T., Sydorenko B., Yakovlev S. Detection of Shoplifting on Video Using a Hybrid Network // Computation. 2022. Vol. 10. No. 11. Art. 199. DOI: 10.3390/computation10110199.

23. Video-Based Detection of Freezing of Gait in Daily Clinical Practice in Patients With Parkinsonism / Kondo Y., Bando K., Suzuki I., Miyazaki Y., Nishida D., Hara T., Kadone H., Suzuki K. // IEEE Transactions on Neural Systems and Rehabilitation Engineering. 2024. Vol. 32. P. 2250–2260. DOI: 10.1109/TNSRE.2024.3413055.

24. Li W., Mahadevan V., Vasconcelos N. Anomaly Detection and Localization in Crowded Scenes // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2014. Vol. 36. No. 1. P. 18–32. DOI: 10.1109/TPAMI.2013.111.

25. Liu W., Luo W., Lian D., Gao S. Future Frame Prediction for Anomaly Detection – A New Baseline // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 6536–6545. DOI: 10.1109/CVPR.2018.00684.

26. Lu C., Shi J., Jia J. Abnormal Event Detection at 150 FPS in MATLAB // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2013. P. 2720–2727. DOI: 10.1109/ICCV.2013.338.

27. Mahadevan V., Li W., Bhalodia V., Vasconcelos N. Anomaly Detection in Crowded Scenes // 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR). 2010. P. 1975–1981.

28. Graph Embedded Pose Clustering for Anomaly Detection / Markovitz A., Sharir G., Friedman I., Zelnik-Manor L., Avidan S. // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. DOI: 10.1109/CVPR42600.2020.01055.

29. Criminal Intention Detection at Early Stages of Shoplifting Cases by Using 3D Convolutional Neural Networks / Martínez-Mascorro G.A., Abreu-Pederzini J.R., Ortiz-Bayliss J.C., Garcia-Collantes A., Terashima-Marín H. // Computation. 2021. Vol. 9. No. 2. Art. 24. DOI: 10.3390/computation9020024.

30. Shoplifting Detection Using Hybrid Neural Network CNN-BiLSMT and Development of Benchmark Dataset / Muneer I., Saddique M., Habib Z., Mohamed H.G. // Applied Sciences. 2023. Vol. 13. No. 14. Art. 8341. DOI: 10.3390/app13148341.

31. Detecting School Violence Using Artificial Intelligence to Interpret Surveillance Video Sequences / Narynov S., Zhumanov Z., Gumar A., Khassanova M., Omarov B. // Advances in Computational Collective Intelligence. ICCCI 2021. 2021. P. 401–412. DOI: 10.1007/978-3-030-88113-9_32.

32. Núñez-Marcos A., Arganda-Carreras I. Transformer-Based Fall Detection in Videos // Engineering Applications of Artificial Intelligence. 2024. Vol. 132. Art. 107937. DOI: 10.1016/j.engappai.2024.107937.

33. Nyajowi T., Oyie N.O., Ahuna M. CNN Real-Time Detection of Vandalism Using a Hybrid-LSTM Deep Learning Neural Networks // 2021 IEEE AFRICON. 2021. P. 1–6. DOI: 10.1109/AFRICON51333.2021.9570902.

34. Keskes O., Noumeir R. Vision-Based Fall Detection Using ST-GCN // IEEE Access. 2021. Vol. 9. P. 28224–28236. DOI: 10.1109/ACCESS.2021.3058219.

35. Automated Analysis and Detection of Epileptic Seizures in Video Recordings Using Artificial Intelligence / Rai P., Knight A., Hiillos M., Kertész C., Morales E., Terney D., Larsen S. A., Østerkjerhuus T.,

Peltola J., Beniczky S. // *Frontiers in Neuroinformatics*. 2024. Vol. 18. Art. 1324981. DOI: 10.3389/fninf.2024.1324981.

36. Shopformer: Transformer-Based Framework for Detecting Shoplifting via Human Pose / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Rahimi Ardabili B., Tabkhi H. // *2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2025. P. 5752–5761. DOI: 10.1109/CVPRW67362.2025.00574.

37. Exploring Pose-Based Anomaly Detection for Retail Security: A Real-World Shoplifting Dataset and Benchmark / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Yao S., Tabkhi H. // *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW)*. 2025.

38. Salido J., Lomas V., Ruiz-Santaquiteria J., Deniz O. Automatic Handgun Detection with Deep Learning in Video Surveillance Images // *Applied Sciences*. 2021. Vol. 11. No. 13. Art. 6085. DOI: 10.3390/app11136085.

39. Sofianos T., Sampieri A., Franco L., Galasso F. Space-Time-Separable Graph Convolutional Network for Pose Forecasting // *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. 2021. P. 11189–11198. DOI: 10.1109/ICCV48922.2021.01102.

40. Sultani W., Chen C., Shah M. Real-World Anomaly Detection in Surveillance Videos // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2018. P. 6479–6488.

41. Connie T., Aderinola T. B., Ong T. S., Goh M. K. O., Erfianto B., Purnama B. Pose-Based Gait Analysis for Diagnosis of Parkinson's Disease // *Algorithms*. 2022. Vol. 15. No. 12. Art. 474. DOI: 10.3390/a15120474.

42. Not Only Look, but Also Listen: Learning Multimodal Violence Detection under Weak Supervision / Wu P., Liu J., Shi Y., Sun Y., Shao F., Wu Z., Yang Z. // *Computer Vision – ECCV 2020*. 2020. DOI: 10.1007/978-3-030-58577-8_20.

43. Cai X., Li S., Liu X., Han G. Vision-Based Fall Detection With Multi-Task Hourglass Convolutional Auto-Encoder // *IEEE Access*. 2020. Vol. 8. P. 44493–44502. DOI: 10.1109/ACCESS.2020.2978249.

44. Towards Surveillance Video-and-Language Understanding: New Dataset, Baselines, and Challenges / Yuan T., Zhang X., Liu K., Liu B., Chen C., Jin J., Jiao Z. // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2024. P. 22052–22061. DOI: 10.1109/CVPR52733.2024.02082.

Басов Олег Олегович, доктор технических наук, доцент, исполнительный директор, Общество с ограниченной ответственностью «СПИЧАП», г. Санкт-Петербург, Россия

Колесникова Анастасия Ильинична, аналитик данных, Акционерное общество «АСТ», г. Москва, 123242, Россия

Basov Oleg Olegovich, Doctor of Technical Sciences, Associate Professor, Executive Director, Limited Liability Company «SPEECHUP», Saint Petersburg, Russia

Kolesnikova Anastasia Ilyinichna, Data Analyst, Joint Stock Company «AST», Moscow, Russia

UDC [303.6+303.7]:001.8

DOI: 10.18413/2518-1092-2026-11-2-0-8

Chigarev B.N.

MAPPING THE SCHOLARLY LANDSCAPE: A BIBLIOMETRIC ANALYSIS OF AI AND EMERGING TECHNOLOGIES ON ARXIV

Institute of Oil and Gas Problems Russian Academy of Sciences,
3 Gubkina St., Moscow, 119333, Russia

e-mail: bchigarev@ipng.ru

Abstract

Artificial intelligence and emerging technologies are boosting research efficiency and global competitiveness, transforming industries. They also raise important social and ethical governance issues that require evidence-based policy decisions. This article presents a two-stage method for identifying relevant research topics in a proof-of-concept format. The first stage involves analyzing bibliometric records of preprints to identify key topics described by terms taken from abstracts. In the second stage, examples of relevant peer-reviewed publications are identified based on these key terms. This method provides a balance between a broad search for relevant topics and reliable verification of scientific results. The data sources used are metadata from ArXiv preprints on artificial intelligence (cs.AI 126,363 records) and emerging technologies (cs.ET 4,497 records) for 2021–2025. The study used 46,493 multi-word terms found in the annotations of cs.AI bibliometric records. To identify relevant peer-reviewed publications, it is advisable to use artificial intelligence-based search engines such as Semantic Scholar, Elicit, or ScienceOS to search for publications using the terminology identified in the first stage. The study shows that the use of a controlled lexicon allows for the identification of 4–5 groups of interpretable topics in text of abstracts, emphasizing the importance of using terms consisting of 2–4 words to achieve optimal results. Optimizing tasks using computing systems based on physical modeling principles supplemented by artificial intelligence could be a promising area of research.

Keywords: bibliometric analysis; artificial intelligence; promising technologies; preprint metadata; key terms; peer-reviewed publications

Acknowledgements: This work was funded by the Ministry of Science and Higher Education of the Russian Federation, State Assignment no. 125021302095-2

For citation: Chigarev B.N. Mapping the Scholarly Landscape: A Bibliometric Analysis of AI and Emerging Technologies on ArXiv // Research result. Information technologies. – T.11, №2, 2026. – P. 91-108. DOI: 10.18413/2518-1092-2026-11-2-0-8

Чигарев Б.Н.

**КАРТИРОВАНИЕ НАУЧНОГО ЛАНДШАФТА:
БИБЛИОМЕТРИЧЕСКИЙ АНАЛИЗ ИССЛЕДОВАНИЙ ИИ
И ПЕРСПЕКТИВНЫХ ТЕХНОЛОГИЙ НА БАЗЕ ARXIV**

Институт проблем нефти и газа РАН,
ул. Губкина, 3, г. Москва, 119333, Россия

e-mail: bchigarev@ipng.ru

Аннотация

Искусственный интеллект и перспективные технологии повышают эффективность научных исследований и глобальную конкурентоспособность, преобразуя отрасли промышленности. Они также поднимают важные социальные и этические вопросы управления, которые требуют принятия политических решений, основанных на фактах. В данной статье представлен двухэтапный метод выявления актуальных тем исследований в формате «доказательства концепции». Первый этап включает анализ библиометрических записей препринтов с целью выявления ключевых тем, описанных терминами, взятыми из аннотаций. На втором этапе на основе этих ключевых терминов выявляются примеры актуальных рецензируемых публикаций. Данный метод обеспечивает баланс между

широким поиском актуальных тем и надежной проверкой научных результатов. В качестве источников данных используются метаданные препринтов ArXiv по искусственному интеллекту (cs.AI 126 363 записи) и перспективным технологиям (cs.ET 4497 записей) за 2021–2025 годы. В исследовании использовались 46 493 многословных термина, найденных в аннотациях библиометрических записей cs.AI. Для выявления соответствующих рецензируемых публикаций рекомендуется использовать поисковые системы на основе искусственного интеллекта, такие как Semantic Scholar, Elicit или ScienceOS, чтобы найти публикации с использованием терминологии, определенной на первом этапе. Исследование показывает, что использование контролируемого лексикона позволяет выделить 4–5 групп интерпретируемых тем в текстах аннотаций, подчеркивая важность использования терминов, состоящих из 2–4 слов, для достижения оптимальных результатов. Оптимизация задач с использованием вычислительных систем на принципах физического моделирования, дополненных искусственным интеллектом, может стать перспективной темой.

Ключевые слова: библиометрический анализ; искусственный интеллект; перспективные технологии; метаданные препринтов; ключевые термины; рецензируемые публикации

Финансирование: Работа выполнена в рамках государственного задания ИПНГ РАН (тема № 125021302095–2).

Для цитирования: Чигарев Б.Н. Картирование научного ландшафта: библиометрический анализ исследований ИИ и перспективных технологий на базе ArXiv // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 91–108. DOI: 10.18413/2518-1092-2026-11-2-0-8

INTRODUCTION

Relevance of the topic Artificial Intelligence and Emerging Technologies

Artificial Intelligence (AI) and Emerging Technologies significantly influence scientific progress, improving the efficiency of research and innovation in various disciplines. In economics, they are changing the landscape of industries and global competitiveness [1]. From a scientific point of view, AI serves as a mechanism for formulating and testing hypotheses, accelerating research [2]. The rapid development of technology also raises pressing social, ethical, and governance issues that require sound, evidence-based policies [3].

Importance of Bibliometric Analysis for AI & Emerging Technologies

Bibliometric analysis plays a key role in understanding contemporary challenges and trends in the dynamic field of AI & Emerging Technologies. This method provides a systematic and quantitative basis for evaluating the extensive literature published on the subject, in contrast to traditional qualitative reviews. By conducting a quantitative analysis of publication metadata, including citations, keywords, authors, and institutions, bibliometrics provides an objective picture of publication activity [4]. In addition, analyzing the co-occurrence of keywords allows researchers to identify new “hot topics” and determine less-studied areas or gaps in research that require further investigation [5, 6].

When conducting bibliometric analysis in the field of artificial intelligence and new technologies, Scopus and Web of Science (WoS) are invariably the main and preferred sources of data, while Arxiv is used much less frequently [7]. This is understandable, since Scopus and WoS are commercial, curated databases that mainly index articles from authoritative peer-reviewed journals and conference proceedings. The peer review process is important for ensuring the quality and reliability of academic analysis. Arxiv, on the other hand, serves as a preprint server that allows for the rapid dissemination of research results but does not guarantee their quality, making it less suitable for the final selection of publications. However, in the preliminary stage of analyzing current topics, Arxiv provides a good overview of current research topics and new algorithms, allowing researchers to quickly familiarize themselves with the full texts of new publications. Moreover, industry R&D is often limited to preprints and does not publish articles in peer-reviewed journals.

ArXiv serves as an important source of preprints in the field of computer science, indexed by significant bibliographic databases such as Scopus and Web of Science. They are of considerable value because they provide insight into current research topics, as they are usually made publicly available 1–2 years before the corresponding peer-reviewed articles appear.

The current trajectory of AI R&D shows that private companies operating in the digital economy, such as Google and Facebook, are playing an increasingly prominent role in fundamental research that was previously the preserve of academia. For example, at the 2022 Neural Information Processing Systems (NeurIPS) conference, the largest annual conference on AI/ML, Google (including DeepMind), Microsoft, and Meta accounted for 12.60% (361) of all accepted papers (2,866), more than twice as many as the second most represented institution, Stanford University [8]. The majority of R&D funding for AI originates from the private sector. In 2022, just 100 companies funded 40% of all AI R&D. Large firms with over 250 employees perform 89% of private-sector AI R&D, indicating that industry has the capital and infrastructure to lead the field.

This article proposes a two-stage approach to identifying relevant research topics in a proof-of-concept format. The first stage involves analyzing numerous bibliometric records of preprints to identify widely represented research topics. The phraseology used is identified from the abstracts of these same data. In the second stage, based on the previously identified keywords, relevant implementations are found in peer-reviewed publications. This approach provides an optimal combination of speed of information retrieval and reliability of scientific results verification.

No direct analogues to the study were found in accessible publications.

ArXiv preprints related to the topics of *Artificial Intelligence* (cs.AI) and *Emerging Technologies* (cs.ET) are used as examples.

MATERIALS AND METHODS

The study was based on bibliometric records exported from the arXiv database for 2021–2025 on the topics of “Artificial Intelligence” (cs.AI) and “New Technologies” (cs.ET), relevant as of December 3, 2025. The export was performed using the arXiv OAI-PMH client. Without deduplication, 126,363 records were downloaded from (cs.AI) and 4,497 from (cs.ET). No duplicates were found in the records. All records had a completed “Abstract” field.

For (cs.ET), only two records with identical English abstracts but different titles were found: ID 2404.11277; “Quantum-inspired Techniques in Tensor Networks for Industrial Contexts” and ID 2404.17645; “Técnicas Quantum-Inspired en Tensor Networks para Contextos Industriales.” The difference between them was that the first preprint was in English, while the second was in Spanish.

For (cs.AI), the share of preprints over 5 years with subsequent peer-reviewed publications is 10.9%. For (cs.ET), the share of preprints over 5 years with subsequent peer-reviewed publications is 25.6%.

Possible explanation: quite often, authors of AI algorithms and methods limit themselves to writing preprints as a detailed explanation of their work and obtaining a DOI.

The study used 46,493 multi-word terms (lowercase letters, no hyphens, lemmatized, deduplicated) found in the abstracts of cs.AI bibliometric records.

A regularly updated dictionary containing 256,000 replacement strings was used for lemmatization.

This dictionary was used for lemmatization of titles and abstracts, as well as a lexicon of multi-word terms frequently found in the abstracts of records related to the topic cs.AI, which will further be referred to as a controlled lexicon on the topic of AI.

The VOSviewer program, version 1.6.20 [9], was used to construct graphs of the co-occurrence of key terms and their clustering.

The occurrence of terms from the AI lexicon in the combined records of titles and abstracts was performed using the ugrep utility.

Note: In this work, key terms and keywords are used interchangeably.

The most frequently occurring terms that reveal the general theme of all bibliometric records: large language model, fine tune, reinforcement learning, machine learning, deep learning, neural network, artificial intelligence, pre train, high quality, decision making. It should be noted that the figure shows lemmatized terms.

The use of a controlled lexicon on a large sample (126,363 entries) yielded a small number of clusters with clearly interpretable themes.

The terms in all tables are presented after lemmatization, in the form in which they are used in the prepared text of the title and abstracts, as well as in the lexicon used for searching.

Table 1 shows the 20 most frequently occurring terms in the first cluster (red) and their Total link strength and Occurrences.

Table 1

The 20 most frequently used terms in the first cluster, revealing the theme of state-of-the-art approaches used by AI

Таблица 1

20 наиболее часто используемых терминов в первом кластере, раскрывающем тему передовых подходов, используемых ИИ

label	Total link strength	Occurrences
state of the art	54054	12888
pre train	31378	6050
fine grain	17322	3961
base model	16432	3501
downstream task	15976	3116
generative model	11827	2764
computer vision	13433	2759
diffusion model	11545	2689
real world dataset	10028	2394
graph neural network	9009	2377
attention mechanism	10108	2242
multi modal	10010	2182
grind truth	8732	2105
supervise learn	10435	2083
representation learn	9498	2014
contrastive learn	8471	1732
achieve state of the art	7520	1702
latent space	7325	1686
data augmentation	8323	1677
transfer learn	8000	1517

Considering the terms *pre train*, *fine grain*, *base model*, *downstream task*, *generative model*, a possible relevant topic could be formulated as the adaptation of a basic generative model to a specific applied task.

Examples of publications that reveal the formulated task include:

The authors of [10] introduced GraphPrompt as a new framework that integrates pre-training and prompting for graph neural networks, addressing the substantial supervision needed in supervised learning. It standardizes the pre-training and downstream tasks within a common template and utilizes a learnable prompt to effectively guide the downstream task in identifying relevant knowledge from the pre-trained model in a task-specific way.

Transfer learning is essential for training deep neural networks on new tasks. This method involves two stages: pseudo pre-training, which utilizes an artificially synthesized dataset from conditional source generative models, and pseudo semi-supervised learning, which employs semi-supervised learning algorithms on labeled target data and generated unlabeled pseudo samples created by combining the source classifier with generative models [11].

Table 2 shows the 20 most frequently occurring terms in the second cluster (green) and their Total link strength and Occurrences.

Table 2

Top 20 terms in the second cluster, revealing the topic of large language models

Таблица 2

20 наиболее частотных терминов во втором кластере, раскрывающих тему больших языковых моделей

label	Total link strength	Occurrences
large language model	69504	18639
fine tune	46408	9140
artificial intelligence	22312	6318
language model	24204	5889
high quality	26150	5692
open source	23114	5389
train data	24523	5294
natural language process	17340	3609
natural language	15692	3595
zero shoot	16989	3469
ai system	9136	2717
domain specific	12109	2341
knowledge graph	8852	2175
question answer	8688	1866
generative ai	5705	1735
evaluation metric	7315	1725
retrieval augment generation	6517	1510
synthetic data	7235	1465
large model	6940	1450
code generation	5493	1271

This topic can be described using the following sequence of terms: *large language model*, *fine-tuning*, *high quality*, *open source*, *domain specificity* are the main properties required for the model. To achieve this, you will need: *training data*, *natural language processing*, *synthetic data*, *knowledge graph*, *evaluation metrics*. Next are the areas of application: *AI system*, *questions and answers*, *generative AI*, *retrieval augment generation*, *code generation*.

Examples of publications that reveal the stated task include:

Fine-tuning entails further training a pretrained model, such as a Large Language Model (LLM), on a custom dataset to tailor it for specific tasks. The review [12] discusses key methodological strategies for fine-tuning LLMs, outlines general steps for the process, and presents specific use cases within medical subspecialties to demonstrate these approaches.

The advancement of Large Language Models for specific applications in materials science and engineering relies on fine-tuning strategies tailored for technical capabilities. The study [13] investigates the impacts of Continued Pretraining, Supervised Fine-Tuning, and preference-based optimization methods like Direct Preference Optimization and Odds Ratio Preference Optimization on LLM performance. Results indicate that merging multiple fine-tuned models can produce capabilities beyond those of individual models, highlighting model merging as a transformative process that fosters significant advancements through nonlinear interactions between model parameters.

Table 3 shows the 20 most frequently occurring terms in the third cluster (blue) and their Total link strength and Occurrences.

Table 3

Top 20 terms in the third cluster, revealing the topic of machine learning

Таблица 3

Топ-20 терминов в третьем кластере, раскрывающем тему машинного обучения

label	Total link strength	Occurrences
machine learn	32342	8109
deep learn	32200	7263
neural network	25772	6679
real time	20104	4786
deep neural network	13535	3276
model performance	14450	3052
deep learn model	13097	2763
black box	11796	2663
machine learn model	9644	2282
high accuracy	8932	2031
loss function	8623	1937
federate learn	7071	1893
convolutional neural network	8456	1790
image classification	7721	1494
deep learn base	6253	1401
large numb	5227	1279
anoma detection	5299	1198
model architecture	5590	1193
feature extraction	5833	1181
train dataset	5285	1085

This topic can be described using the following sequence of terms: *machine learning*, *deep learning*, *deep neural network*, *deep learning model*, *machine learning model*, *federated learning*, these terms reflect the subject matter itself. To implement this, a *train dataset* and *large numbers* are required. Implementation requires: *real time*, *high accuracy*, *loss function*, and *feature extraction*. The main applications are: *image classification* and *anomaly detection*.

If *train data* is used for a *large language model*, then for *machine learning* → *train dataset*.

Examples of publications that reveal the task described by the terms *machine learning*, *real time*, *deep neural network*, and *model performance*:

A computer vision approach for real-time object detection on low-power devices is both economically appealing and technically challenging. The paper [14] presents benchmark results on popular deep neural network models, offering insights into the trade-offs among accuracy, speed, and computational efficiency.

The paper [15] discusses benchmarks for popular deep neural network models, focusing on trade-offs among accuracy, speed, and computational efficiency crucial for real-time operation in production. It highlights the impact of inference latency, throughput, and resource utilization on user experience, service reliability, and operational costs. The paper emphasizes the necessity of real-time monitoring to address inconsistencies in input data and workload fluctuations, ensuring efficiency and integrity across various deployment environments, including cloud-hosted services, data centers, and edge devices.

Table 4 shows the 20 most frequently occurring terms in the fourth cluster (khaki) and their Total link strength and Occurrences.

Table 4

Top 20 terms in the fourth cluster, revealing the topic of reinforcement learning

Таблица 4

Топ-20 терминов в четвертом кластере, раскрывающем тему обучения с подкреплением

label	Total link strength	Occurrences
reinforcement learn	33978	8374
decision make	22983	5526
high level	12572	2882
multi agent	10521	2581
deep reinforcement learn	7986	2043
model base	8515	1940
autonomous drive	7448	1578
success rate	6232	1516
reward function	5853	1284
optimization problem	4476	1215
low level	5664	1214
prior knowledge	5333	1199
real world data	4255	987
learn algorithm	3592	969
autonomous vehicle	4078	968
multi agent system	3544	894
imitation learn	3538	858
human feedback	4353	843
reward model	3793	760
learn framework	3151	742

Deep reinforcement learning is a highly sought-after topic, especially in tasks such as *decision making, multi-agent systems, autonomous driving, and autonomous vehicles*. To achieve this, it is necessary to have: *real-world data, prior knowledge, imitation learning, human feedback, and a learning framework*.

Examples of publications that reveal the task described by the terms *deep reinforcement learning, decision making, and multi-agent system*:

The article [16] aims to provide an overview of current multiagent deep reinforcement learning (MDRL) literature, revisiting key components adapted from MAL and RL. It also offers guidelines for new practitioners, discusses lessons learned, recent benchmarks, and outlines research opportunities. Additionally, it critically addresses practical challenges associated with MDRL, such as implementation and computational requirements.

The article [17] discusses the significance of multiagent deep reinforcement learning (MADRL) in scenarios where multiple agents must communicate and collaborate to tackle complex tasks. It surveys various approaches to addressing challenges in MADRL, including nonstationarity, partial observability, continuous state and action spaces, multiagent training schemes, and transfer learning. The merits and drawbacks of these methods are analyzed, along with their applications.

The fifth cluster is the smallest, so we will only provide a list of the main terms describing it: *foundation model, task specific, pre-train model, vision language model, multimodal large language model, continual learning, catastrophic forgetting, vision language, visual question answering, mixture of experts, image captioning, image and text, parameter efficient, parameter efficient fine-tuning, large vision language model, low rank adaptation, vision model, vision and language, large multimodal model, multimodal LLM*. The most interesting topics seem to be *vision language model, large vision language model, image and text*.

The use of a controlled thematic lexicon in combination with extensive bibliometric records leads to the formation of a limited number of easily interpretable clusters. During text analysis, spelling errors or new terms are inevitably identified, but since the lexicon is a regular text file, it is easy to make changes to it.

Terms from the AI lexicon found in each of the combined records of titles and abstracts of bibliometric records belonging to the cs.ET class and formed as “ET Keywords.” Figure 3 shows the result of clustering “ET Keywords” using the VOSviewer program.




Fig. 3. Landscape of research topics in the field of Emerging Technologies based on the co-occurrence of ET keywords according to ArXiv data (2021–2025)

Рис. 3. Ландшафт исследовательских тем в области перспективных технологий на основе совместной встречаемости ключевых слов ET по данным ArXiv (2021–2025 гг.)

Summary of the graph based on data from app.vosviewer.com: Items: 300 | Links: 4293 | Total link strength: 10805 | Clusters: 5

A significant difference between Emerging Technologies and AI are clusters: #3 with terms: *quantum computing, quantum computer, quantum circuit, quantum hardware, quantum computation, quantum machine learning*; #4 with terms: *quantum annealing, combinatorial optimization problem, Ising Machine, quadratic unconstrained binary optimization, quantum annealers, combinatorial optimization, Monte Carlo*; and #1, in which the term *energy efficiency* appears among the terms *machine learning, neural network, artificial intelligence, deep learning, neuromorphic computing, and deep neural network*. The latter may indicate that the methods listed are important for *energy efficiency* and that *energy* is important for implementing these methods.

Table 5 shows the 20 most frequently occurring terms in the first cluster (red) and their Total link strength and Occurrences.

Table 5

Top 20 terms in the first cluster (red) reflecting the current tasks of Emerging Technologies

Таблица 5

20 наиболее часто встречающихся терминов в первом кластере (красный цвет), отражающих текущие задачи в области перспективных технологий

label	Total link strength	Occurrences
machine learn	1138	425
neural network	928	352
energy efficiency	720	288
artificial intelligence	583	268
deep learn	510	207
neuromorphic compute	399	165
deep neural network	366	150
memory compute	364	136
spike neural network	263	121
artificial neural network	252	90
reservoir compute	158	79
convolutional neural network	219	78
neuromorphic hardware	181	71
matrix multiplication	173	60
optical neural network	159	59
volatile memory	126	58
photonic neural network	143	55
integrate circuit	95	52
magnetic tunnel junction	128	50
activation function	144	45

Energy efficiency is a crucial term within the context of machine learning, neural networks, and artificial intelligence, highlighting the significant energy costs associated with these technologies.

This topic covers various aspects such as energy efficiency, optimizing energy networks, and data center energy use for AI, supported by relevant publications.

The research [18] examines the application of Machine Learning and AI in enhancing energy efficiency, predicting energy consumption trends, and optimizing energy systems in the USA. Utilizing datasets related to household energy usage, electric vehicle trends, and smart grid analytics, the study employs advanced techniques like deep learning, regression models, and ensemble learning to improve forecasting accuracy for better resource allocation.

The integration of Artificial Intelligence into energy systems enhances smart grid infrastructures by automating processes, improving demand forecasting, and optimizing grids. However, this combination introduces significant challenges concerning safety and security. The paper [19] analyzes the cybersecurity implications of AI in smart grids, focusing on the role of IoT systems and decentralized energy resources, while evaluating existing cybersecurity frameworks to identify vulnerabilities within an AI-enabled grid ecosystem.

Large language models (LLMs) are transforming technology and daily life, driven by extensive training on vast datasets. However, the significant electricity demand for their training and inference presents a critical challenge. The review paper [20] examines the LLM lifecycle, focusing on estimating electricity consumption and carbon emissions using statistical data.

Table 6 shows the 20 most frequently occurring terms in the second cluster (green) and their Total link strength and Occurrences.

Table 6

Top 20 terms in the second cluster (green) reflecting the current tasks of Emerging Technologies

Таблица 6

20 наиболее часто встречающихся терминов во втором кластере (зеленый цвет), отражающих текущие задачи в области перспективных технологий

label	Total link strength	Occurrences
molecular communication	96	90
internet of thing	135	87
reconfigurable intelligent surface	152	82
base station	90	35
unman aerial vehicle	77	32
deep reinforcement learn	92	30
noise ratio	76	30
communication technology	31	24
energy harvest	43	24
radio frequency	48	23
random forest	64	22
alternate optimization	56	21
user equipment	42	21
bite error rate	52	20
channel estimation	42	20
channel state information	38	20
integrate sense and communication	42	20
intelligent reflect surface	40	20
spectral efficiency	48	19
chemical reaction network	20	18

The *reconfigurable intelligent surface* ranks third in frequency, but has the highest Total link strength, as does the Internet of Things. The Internet of Things, reconfigurable intelligent surfaces, and base stations are important in communication technology, involving energy harvesting, radio frequency, and channel state information.

More details on this task can be found in [21], which offers a review and categorization of current RIS positioning research, along with insights into future directions. Reconfigurable intelligent surfaces (RIS) are proposed as a potential technology for 6G wireless communication, particularly in integration with IoT for positioning applications.

Another topic worthy of attention may be the one described by the terms: *molecular communication* and *chemical reaction network*.

Molecular communication aims to transmit information using molecules, while *chemical reaction networks* offer models and methods for this.

Table 7 shows the 20 most frequently occurring terms in the third cluster (blue) and their Total link strength and Occurrences.

Table 7

Top 20 terms in the third cluster (blue) reflecting the current tasks of Emerging Technologies

Таблица 7

20 наиболее часто встречающихся терминов в третьем кластере (синий цвет), отражающих текущие задачи в области новых технологий

label	Total link strength	Occurrences
quantum compute	1128	486
quantum computer	738	305
quantum circuit	653	303
quantum hardware	360	117
quantum computation	226	96

quantum machine learn	296	86
reinforcement learn	172	76
classical computer	213	63
quantum approximate optimization algorithm	134	59
state of the art	103	46
quantum neural network	151	39
computer science	65	38
quantum error correction	93	38
variational quantum algorithm	105	36
classical counterpart	117	35
search algorithm	52	27
quantum process unit	65	26
software engineer	51	25
parameterize quantum circuit	82	24
variational quantum eigensolv	60	23

The dominant theme of this cluster revolves around *quantum computing* and its application in *quantum reinforcement learning* (QRL). Key concepts include *quantum circuits*, *quantum hardware*, and *quantum machine learning*. QRL involves utilizing principles and algorithms from *quantum computing* to improve the efficiency of *classical reinforcement learning systems*. The distinct feature of quantum principles, like superposition, enables an reinforcement learning agent to simultaneously explore multiple states and actions, thereby accelerating the learning process.

A good instance is the publication [22], which highlights Quantum Reinforcement Learning through Variational Quantum Circuits, achieving a 90% reduction in trainable parameters and enhanced efficiency in reinforcement learning tasks, emphasizing QRL's scalability and suitability for complex scenarios.

Table 8 presents the 20 most frequently occurring terms in the fourth cluster (khaki) and their Total Link Strength and Occurrences.

Table 8

Top 20 terms in the fourth cluster (khaki) reflecting current tasks in Emerging Technologies

Таблица 8

20 наиболее часто встречающихся терминов в четвертом кластере (хаки), отражающих текущие задачи в области новых технологий

label	Total link strength	Occurrences
quantum anneal	269	110
combinatorial optimization problem	257	100
ize machine	155	76
quadratic unconstrained binary optimization	175	64
quantum annealers	149	59
combinatorial optimization	126	43
monte carlo	98	37
simulate anneal	121	35
proof of concept	56	27
travel salesman problem	60	25
probabilistic compute	51	20
genetic algorithm	44	17
differential equation	34	14
random numb generator	40	14
coherent ize machine	31	13
full connect	35	13
boltzmann machine	45	12
stochastic magnetic tunnel junction	38	12
boolean satisfiability	24	11
random numb generation	26	11

Using exported bibliometric records related to the cs.ET class, a network was constructed reflecting the relationship between cs.ET and other classes. The results are shown in Figure 4.




Рис. 4. Сеть совместной встречаемости классов ArXiv, к которым отнесены записи по теме cs.ET (Передовые технологии)

In the graph, the red cluster cs.ET, associated with the *quant-ph* class, has 1015 occurrences, while the green cluster cs.AI has 740 occurrences, indicating that cs.AI is not the most common class co-occurring with cs.ET.

Table 9 shows the main characteristics of the most common classes presented in Figure 4.

Table 9

Five most frequently occurring classes in records related to cs.ET

Таблица 9

Пять наиболее часто встречающихся классов в записях, относящихся к cs.ET

label	Total link strength	Occurrences	Avg. pub. year
cs.et	7693	4497	2023.4505
quant-ph	1768	1015	2022.8108
cs.lg	2130	794	2023.8275
cs.ai	2102	740	2024.2689
cs.ar	855	406	2023.4433

In the context of cs.ET, cs.AI topics rank only third after quant-ph and cs.LG (Machine Learning), but they appear more frequently in new publications: Avg. pub. year = 2024.2689. And Total Link Strength for cs.AI is greater than that for quant-ph.

Note: quant-ph – Quantum Physics; cs.LG – Machine Learning; cs.AR – Hardware Architecture.

The intersection of cs.ET and cs.AI topics can be effectively defined through the use of preprint metadata, which offers public and rapid access. For selecting trustworthy sources as research examples, it is advisable to concentrate on publications found in highly ranked journals.

Data obtained can identify relevant publications in peer-reviewed journals. The sample includes works related to cs.ET and cs.AI, with the ArXiv platform allowing retrieval of DOIs for publications where preprint materials are posted.

As an example, let us consider the topic of decision-making and its implementation in the fields of cs.ET and cs.AI. Analysis of exported bibliometric data shows that such work could be the article [25], in which "The authors developed Yodeai to enhance knowledge work processes, enabling information professionals to explore and synthesize unstructured data, such as product reviews and customer interview transcripts, through interactive widgets—customizable templates that convert unstructured data into structured insights".

Experts in their field are well acquainted with publications on their subject, but less familiar with research in related fields. A formalized approach to searching for relevant topics can facilitate the study of issues beyond familiar boundaries, in particular by transferring knowledge from other fields facing similar problems. However, experts rarely conduct comprehensive bibliometric analysis in related fields of knowledge.

SEVERAL ASPECTS CONCERNING FURTHER WORK WITH THE LEXICON

This section highlights the need for further research on the compilation and editing of controlled vocabularies. The VOSviewer program used in bibliometric analysis employs 1,000 terms by default to construct a network of related terms. First, terms that appear 5 or more times are selected, and from these, 1,000 terms with the highest overall connection strength are picked. Analysis of the cs.AI sample shows that of these 1,000 terms, 29 consist of 5 words, 43 consist of 4 words, 247 consist of 3 words, 659 consist of 2 words, and indicates 22 terms that should be excluded from the lexicon, such as *state of the art large language model*.

Given that there are only a few terms containing five words, it is advisable to manually save only those that are relevant to the research being conducted, such as: *pre train large language model*, *multi modal large language model*, *fine tune large language model*, *cooperative multi agent reinforcement learning*, *multi agent deep reinforcement learning*. Such a change in the lexicon is largely subjective, but subjectivity is unavoidable when analyzing text to identify relevant topics for research. The same applies to terms consisting of 4 and fewer terms, but this is a more extensive task.

Further research should analyze the sequence of searching for multi-word terms. In this work, the search for the longest substrings was implemented first, followed by shorter ones. However, a more accurate

method should take into account the “shielding” effect of words in complex terms. For example, in a situation where the phrase “supervise fine tune large language model” is present in the text, but there is no corresponding long term in the lexicon, the term “fine tune large language model” may overshadow the match for “supervise fine tune.”

Another issue not addressed by this research method is that repeated terms can be important, especially when comparing abstracts using the weighted Jaccard similarity coefficient. In abstracts, the abbreviation is often written with its full form the first time it appears, and then only as an abbreviation thereafter. However, abbreviations can have different meanings in a set of texts, for example, A2A → agent to agent; all-to-all; agriculture to agriculture; or AA → autonomous agent; authorship attribution; actuation attacks; adversarial attacks; anomaly assumption; archetypal analysis. Therefore, abbreviations must be replaced separately in each abstract.

CONCLUSIONS

The study shows that using a controlled lexicon of multi-word terms from titles and abstracts, as an analogue to Scopus Index keywords, yields easily interpretable results. This highlights 4–5 clusters of co-occurring terms that effectively describe understandable topics. This applies to both a large sample of 126,363 bibliometric records and an average sample of 4,497 records. The study results suggest focusing on terms consisting of 2-4 words to achieve optimal results.

Updating and editing a controlled lexicon is the most time-consuming process, primarily because it is difficult to formalize as it is quite subjective. This subjectivity affects the prioritization of relevant research topics. The need to precisely define key terms arises from the absence of keywords in many exported records from high-quality sources of bibliometric records, such as ArXiv, OnePetro, and Dimensions.ai.

The proposed two-stage method for identifying promising research topics, which involves extracting relevant terminology from a large sample of new open-access preprints and then conducting a targeted search for related publications in highly cited journals, has shown its effectiveness. To identify relevant peer-reviewed publications, both ArXiv metadata and artificial intelligence-based search engines such as Semantic Scholar, Elicit, or ScienceOS can be used to find publications based on the terminology found in the first stage.

Among promising research topics, it is worth highlighting one that lies at the intersection of cs.AI and cs.ET: solving complex combinatorial optimization problems using physical systems inspired by quantum mechanics or statistical physics and AI. That is, the use of a hybrid algorithm in which a quantum processor or its simulation solves combinatorially complex problems, while classical AI optimizes parameters to find the global minimum. AI acts as a “parameter optimizer.” It tunes the quantum circuit to obtain increasingly accurate results, learning at each stage.

Among the tasks that need to be continued as separate studies, we can highlight the expansion and editing of the controlled lexicon for specific research purposes. Another task is to justify the choice of a reasonable sequence for searching for multi-word terms in texts, taking into account that they may contain the same words.

Explanation: Identifying relevant topics for research does not replace the work of experts, but it reduces bias in selection and simplifies the search for resources for transferring knowledge from one field to another.

References

Список литературы

1. Yuan C. et al. The Impact of Artificial Intelligence on Economic Development: A Systematic Review: The impact of artificial intelligence on economic development // ITPHSS. 2024. V. 1, No 1. P. 130–143. DOI: 10.70693/itphss.v1i1.57

2. Erduran S., Levrini O. The impact of artificial intelligence on scientific practices: an emergent area of research for science education // International Journal of Science Education. 2024. V. 46, No 18. P. 1982–1989. DOI: 10.1080/09500693.2024.2306604
3. Levy H.V. Ethical, legal, and governance dimensions of responsible research and innovation: global perspectives and challenges in emerging technologies // Law, Ethics & Technology. 2025. DOI: 10.55092/let20250012
4. Triana I. et al. Artificial Intelligence in Innovation Research a Bibliometric Perspective // 2024 3rd International Conference on Creative Communication and Innovative Technology (ICCIT). Tangerang, Indonesia: IEEE, 2024. P. 1–6. DOI: 10.1109/ICCIT62134.2024.10701113
5. Lis A. Keywords Co-occurrence Analysis of Research on Sustainable Enterprise and Sustainable Organisation // Journal of Corporate Responsibility and Leadership. 2018. V. 5, No 2. P. 47–66. DOI: 10.12775/JCRL.2018.011
6. Koştı G., Kayadibi İ. A bibliometric analysis of artificial intelligence and machine learning applications for human resource management // Futur Bus J. 2025. V. 11, No 1. P. 179. DOI: 10.1186/s43093-025-00602-x
7. Mariani M.M. et al. Artificial intelligence in innovation research: A systematic review, conceptual framework, and future research directions // Technovation. 2023. V. 122. P. 102623. DOI: 10.1016/j.technovation.2022.102623
8. Jurowetzki R. et al. The private sector is hoarding AI researchers: what implications for science? // AI & Soc. 2025. V. 40, No 5. P. 4145–4152. DOI: 10.1007/s00146-024-02171-z
9. Van Eck N.J., Waltman L. Software survey: VOSviewer, a computer program for bibliometric mapping // Scientometrics. 2010. V. 84, No 2. P. 523–538. DOI: 10.1007/s11192-009-0146-3
10. Liu Z. et al. GraphPrompt: Unifying Pre-Training and Downstream Tasks for Graph Neural Networks // Proceedings of the ACM Web Conference 2023. Austin TX USA: ACM, 2023. P. 417–428. DOI: 10.1145/3543507.3583386
11. Yamaguchi S. et al. Transfer learning with pre-trained conditional generative models // Mach Learn. 2025. V. 114, No 4. P. 96. DOI: 10.1007/s10994-025-06748-7
12. Anisuzzaman D.M. et al. Fine-Tuning Large Language Models for Specialized Use Cases // Mayo Clinic Proceedings: Digital Health. 2025. V. 3, No 1. P. 100184. DOI: 10.1016/j.mcpgdig.2024.11.005
13. Lu W., Luu R.K., Buehler M.J. Fine-tuning large language models for domain adaptation: exploration of training strategies, scaling, model merging and synergistic capabilities // npj Comput Mater. 2025. V. 11, No 1. P. 84. DOI: 10.1038/s41524-025-01564-y
14. Institute of Information Technology and Intelligent Systems, Kazan Federal Universit et al. Comparative analysis of neural network models performance on low-power devices for a real-time object detection task // Computer Optics. 2024. V. 48, No 2. P. 242–252. DOI: 10.18287/2412-6179-CO-1343
15. Real-Time Performance Monitoring for Deep Learning Models in Production // International Journal of Intelligent Systems and Applications in Engineering. 2024. DOI: 10.17762/ijisae.v12i23s.7764
16. Hernandez-Leal P., Kartal B., Taylor M.E. A survey and critique of multiagent deep reinforcement learning // Auton Agent Multi-Agent Syst. 2019. V. 33, No 6. P. 750–797. DOI: 10.1007/s10458-019-09421-1
17. Nguyen T.T., Nguyen N.D., Nahavandi S. Deep Reinforcement Learning for Multiagent Systems: A Review of Challenges, Solutions, and Applications // IEEE Trans. Cybern. 2020. V. 50, No 9. P. 3826–3839. DOI: 10.1109/TCYB.2020.2977374
18. Ibeh C.V., Adegbola A. AI and Machine Learning for Sustainable Energy: Predictive Modelling, Optimization and Socioeconomic Impact in the USA // IJASRaR. 2025. V. 2, No 1. DOI: 10.22399/ijasrar.19
19. Fathy R.A. Artificial Intelligence in the Energy Sector: Regulatory Compliance, Challenges, and Cybersecurity Implications // 2025 IEEE Conference on Power Electronics and Renewable Energy (CPERE). Aswan, Egypt: IEEE, 2025. P. 1–6. DOI: 10.1109/CPERE65146.2025.11240055
20. Ji Z., Jiang M. A systematic review of electricity demand for large language models: evaluations, challenges, and solutions // Renewable and Sustainable Energy Reviews. 2026. V. 225. P. 116159. DOI: 10.1016/j.rser.2025.116159
21. Chen R. et al. Reconfigurable Intelligent Surfaces for 6G IoT Wireless Positioning: A Contemporary Survey // IEEE Internet Things J. 2022. V. 9, No 23. P. 23570–23582. DOI: 10.1109/IIOT.2022.3203890
22. Ravish R. et al. Optimization of Reinforcement Learning Using Quantum Computation // IEEE Access. 2024. V. 12. P. 179396–179417. DOI: 10.1109/access.2024.3506656
23. Heng S. et al. How to Solve Combinatorial Optimization Problems Using Real Quantum Machines: A Recent Survey // IEEE Access. 2022. V. 10. P. 120106–120121. DOI: 10.1109/ACCESS.2022.3218908

24. Panda S., Gadam H., Upadhyay A. INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING // SSRN Journal. 2025. DOI: 10.2139/ssrn.527140310

25. Yun B. et al. Generative AI in Knowledge Work: Design Implications for Data Navigation and Decision-Making // Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems. Yokohama Japan: ACM, 2025. P. 1–19. DOI: 10.1145/3706598.3713337

Чигарев Борис Николаевич, кандидат физико-математических наук, старший научный сотрудник Аналитического центра энергетической политики и безопасности, Институт проблем нефти и газа РАН, г. Москва, Россия

Chigarev Boris Nikolaevich, Candidate of Physical and Mathematical Sciences, Senior Researcher of Analytical Center for Energy Policy and Security, Institute of Oil and Gas Problems Russian Academy of Sciences, Moscow, Russia

УДК 004.896:519.85

DOI: 10.18413/2518-1092-2026-11-2-0-9

Зарипов Е.А.
Лазаренко С.А.

**ОПТИМИЗАЦИЯ ГИПЕРПАРАМЕТРОВ
МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ
НА ОСНОВЕ ЭВОЛЮЦИОННЫХ АЛГОРИТМОВ
И СУРРОГАТНОГО МОДЕЛИРОВАНИЯ**

Российский технологический университет МИРЭА
проспект Вернадского, д. 78, г. Москва, 119454, Россия

e-mail: e.a.zaripov@ya.ru, sergey.lazarenko.0241@mail.ru

Аннотация

Актуальность. Построение высокоточных предиктивных моделей в современных интеллектуальных системах требует автоматизации поиска оптимальных гиперпараметров. Традиционные методы оптимизации демонстрируют низкую эффективность в пространствах высокой размерности и при значительных вычислительных затратах на оценку целевой функции, что обуславливает необходимость разработки новых подходов на стыке эвристического поиска и статистической аппроксимации.

Проблема. Основная сложность заключается в необходимости нахождения глобального экстремума функции «черного ящика» при жестком ограничении бюджета вычислений. Высокая ресурсоемкость каждого обращения к полной модели машинного обучения требует минимизации количества итераций без потери точности и робастности финального решения.

Методы. Предложен гибридный алгоритм EA-SM, интегрирующий механизмы эволюционного поиска и адаптивного суррогатного моделирования на основе гауссовских процессов. Математический аппарат включает использование функции сбора данных для балансировки исследования пространства и эксплуатации найденных минимумов, а также регуляризацию Тихонова для обеспечения вычислительной устойчивости матриц ковариации.

Результаты. Экспериментальная верификация на задачах классификации стохастических объектов и прогнозирования временных рядов (AutoForecast, Chronos) подтвердила превосходство метода. Установлено сокращение числа обращений к целевой функции на 30–70% по сравнению с алгоритмами DIRECT и Optuna при сохранении высокой точности аппроксимации в окрестностях экстремумов.

Выводы. Разработанный подход обеспечивает асимптотическую сходимость к глобальному оптимуму и устойчивость к стохастическому шуму. Алгоритм пригоден для настройки нейросетевых архитектур в условиях высокой размерности, минимизируя временные и аппаратные затраты в системах мониторинга и обнаружения аномалий.

Ключевые слова: оптимизация гиперпараметров; эволюционные алгоритмы; суррогатное моделирование; гауссовские процессы; активное обучение; машинное обучение; глобальный экстремум; вычислительная эффективность; временные ряды; автоматизированное машинное обучение

Для цитирования: Зарипов Е.А., Лазаренко С.А. Оптимизация гиперпараметров моделей машинного обучения на основе эволюционных алгоритмов и суррогатного моделирования // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 109-120. DOI: 10.18413/2518-1092-2026-11-2-0-9

Zaripov E.A.
Lazarenko S.A.

OPTIMIZATION OF HYPERPARAMETERS OF MACHINE LEARNING MODELS BASED ON EVOLUTIONARY ALGORITHMS AND SURROGATE MODELING

Russian Technological University MIREA
Prospekt Vernadskogo, 78, Moscow, 119454, Russia

e-mail: e.a.zaripov@ya.ru, sergey.lazarenko.0241@mail.ru

Abstract

Relevance. Building high-precision predictive models in modern intelligent systems requires automating the search for optimal hyperparameters. Traditional optimization methods demonstrate low efficiency in high-dimensional spaces and with significant computational costs for estimating the objective function, which necessitates the development of new approaches at the interface of heuristic search and statistical approximation.

Problem. The main difficulty lies in the need to find the global extremum of the «black box» function with a strict limitation of the computing budget. The high resource intensity of each access to the complete machine learning model requires minimizing the number of iterations without losing the accuracy and robustness of the final solution.

Methods. A hybrid EA-SM algorithm is proposed that integrates the mechanisms of evolutionary search and adaptive surrogate modeling based on Gaussian processes. The mathematical apparatus includes the use of a data collection function to balance space exploration and exploit the found minima, as well as Tikhonov regularization to ensure the computational stability of covariance matrices.

Results. Experimental verification on the tasks of stochastic object classification and time series forecasting (AutoForecast, Chronos) confirmed the superiority of the method. A reduction in the number of calls to the objective function by 30-70% has been found compared to the DIRECT and Optuna algorithms, while maintaining high approximation accuracy in the vicinity of extremes.

Conclusions. The developed approach provides asymptotic convergence to the global optimum and resistance to stochastic noise. The algorithm is suitable for configuring neural network architectures in high-dimensional environments, minimizing time and hardware costs in monitoring and anomaly detection systems.

Keywords: hyperparameter optimization; evolutionary algorithms; surrogate modeling; Gaussian processes; active learning; machine learning; global extremum; computational efficiency; time series; automated machine learning

For citation: Zaripov E.A., Lazarenko S.A. Optimization of Hyperparameters of Machine Learning Models Based on Evolutionary Algorithms and Surrogate Modeling // Research result. Information technologies. – T.11, №2, 2026. – P. 109-120. DOI: 10.18413/2518-1092-2026-11-2-0-9

ВВЕДЕНИЕ

Сложная архитектура современных нейросетей и расширение сфер их применения делают задачу автоматической настройки моделей крайне важной [5, 16]. Подбор оптимальных гиперпараметров напрямую влияет на то, насколько эффективно алгоритм будет работать с новыми данными и сколько вычислительных ресурсов ему потребуется. При этом классические подходы, такие как поиск по сетке (Grid Search) или случайный поиск (Random Search), перестают работать, если пространство параметров слишком велико, а один запуск модели занимает много времени [2].

Разработки в области автоматизированного машинного обучения (AutoML) как раз нацелены на то, чтобы исключить ручную настройку и минимизировать участие человека в этом процессе [21, 23]. Особую роль это играет при анализе временных рядов, где из-за постоянных изменений в данных модель приходится регулярно переобучать [10, 15, 24]. В таких задачах функция, которая связывает набор гиперпараметров с итоговым качеством модели на валидационной выборке,

представляет собой типичный «черный ящик». Ее точный математический вид неизвестен, а каждый расчет оборачивается серьезными затратами времени и мощностей процессора [13, 18].

Для решения задач оптимизации в условиях ограниченного бюджета вычислений активно применяются стратегии, использующие аппроксимацию. Суррогатное моделирование направлено на построение статистической или аналитической модели $\hat{f}$, которая имитирует поведение истинной функции f , но вычисляется значительно быстрее [3, 14]. Математический аппарат таких моделей базируется на теории гауссовских процессов или радиально-базисных функций. Интеграция суррогатов в структуру эволюционных алгоритмов (ЕА) открывает новые возможности для глобального поиска [20, 22]. Эволюционные подходы, имитирующие механизмы естественного отбора, обеспечивают эффективное исследование пространства $\mathcal{H}$, в то время как суррогаты сокращают количество обращений к исходной функции f .

В современной практике стохастического моделирования базовый инструментарий оптимизации гиперпараметров зачастую опирается на готовые программные комплексы (в частности, фреймворк Optuna), модули которых реализуют аппарат байесовского поиска и алгоритмические схемы древовидных парзеновских оценок (TPE) [11]. Тем не менее, вычислительная эффективность подобных систем существенно снижается при обработке целевых функций в условиях специфических краевых ограничений - например, при идентификации стохастически нестабильных объектов или экспресс-анализе аномалий в массивах данных, где классические подходы обнаруживают слабую скорость сходимости [6, 7]. Ситуация критически усложняется в топологических зонах с разрывным характером исследуемых функций либо при наличии латентных (неявных) ограничений аргументов [13, 19].

Как показано в фундаментальных исследованиях [17, 18], альтернативным вектором решения выступает применение глобально-ориентированных детерминированных процедур, среди которых выделяется алгоритм DIRECT (Dividing Rectangles), базирующийся на систематическом разбиении гиперкубических областей пространства поиска. На стыке указанных подходов формируется самостоятельное научное направление, ориентированное на интеграцию жестко детерминированных схем с эволюционными эвристиками и концепцией активного обучения посредством комитетов аппроксимирующих моделей [17, 22]. В настоящей статье авторами предлагается оригинальное развитие методологии гибридизации: в контур стохастического поиска имплементированы адаптивные суррогатные модели. Теоретическим фундаментом предлагаемого решения и гарантом его вычислительной устойчивости служит доказанная сходимость последовательностей случайных величин, заданных в метрических пространствах.

Важной составляющей анализа является математическое обоснование устойчивости предложенных стратегий [1]. В социально-экономических системах или при обработке многокритериальных задач оптимизации необходимо учитывать не только точность, но и робастность получаемых решений [1, 3]. Применение градиентных методов в таких случаях ограничено из-за отсутствия дифференцируемости целевой функции в дискретных или категориальных подпространствах $\mathcal{H}$.

Таким образом, разработка алгоритмов, сочетающих глобальный охват эволюционных методов и локальную точность суррогатной аппроксимации, становится приоритетной задачей для развития математического обеспечения современных интеллектуальных систем [8, 9, 12].

Цель работы заключается в разработке и математическом обосновании гибридного алгоритма оптимизации гиперпараметров моделей машинного обучения, объединяющего механизмы эволюционного поиска и адаптивного суррогатного моделирования для повышения эффективности поиска глобального экстремума в условиях ограниченных вычислительных ресурсов.

МАТЕРИАЛЫ И МЕТОДЫ ИССЛЕДОВАНИЯ

Для проведения исследования использованы методы математического анализа, теории вероятностей и математической статистики. Объектом оптимизации выступает функционал ошибки модели машинного обучения на заданном множестве гиперпараметров.

Предложенный метод основан на циклическом процессе:

1. Формирование начальной выборки точек в пространстве $\mathcal{H}$ с использованием последовательностей Соболя или латинского гиперкуба.
2. Построение суррогатной модели $\hat{f}$ на основе ансамбля регрессионных деревьев или гауссовских процессов [3, 4].
3. Запуск эволюционного алгоритма (дифференциальная эволюция или алгоритм роя частиц) над функцией $\hat{f}$ для нахождения суррогатных минимумов.
4. Вычисление истинного значения $f(h)$ в точках, обладающих наибольшим потенциалом улучшения, и обновление базы данных [22].

В качестве тестовых задач выбраны модели классификации временных рядов и тематического моделирования [12, 9]. Математическое описание пространства поиска включает как непрерывные (скорость обучения), так и дискретные (количество слоев, тип активации) переменные. Эффективность оценивается через индикатор IGD (Инвертированное расстояние поколений) и скорость сходимости к известным глобальным минимумам стандартных тестовых функций [20].

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

Автоматическая настройка гиперпараметров в современных предиктивных моделях сводится к задаче глобальной оптимизации. Мы рассматриваем минимизацию целевой функции $f(x)$, заданной на некотором компактном пространстве $H \subset R^d$, где d – количество оптимизируемых параметров. Поиск наилучшей конфигурации x^* описывается стандартным уравнением:

$$x^* = \underset{x \in H}{\operatorname{argmin}} f(x) \quad (1)$$

Чтобы гарантировать корректную работу алгоритмов в условиях, когда точный аналитический вид функции $f(x)$ неизвестен (принцип «черного ящика»), а каждое ее вычисление требует значительных ресурсов ЭВМ, мы используем суррогатное моделирование. Базовым инструментом здесь выступают гауссовские процессы. Они позволяют аппроксимировать целевую функцию на основе уже накопленных в ходе экспериментов данных, оценивая не только наиболее вероятное значение функции в новых точках, но и математическую неопределенность (дисперсию) этой оценки.

Для выбора следующих наиболее перспективных точек пространства параметров применяется аппарат функций сбора данных (acquisition functions). В разработанном алгоритме баланс между исследованием малоизученных областей и эксплуатацией уже найденных локальных минимумов обеспечивается за счет критерия нижней доверительной границы (Lower Confidence Bound, LCB):

$$S_t(x) = \mu_t(x) - \kappa \sigma_t(x) \quad (2)$$

В данном выражении $\mu_t(x)$ означает ожидаемое значение целевой функции, вычисленное суррогатной моделью на шаге t , а $\sigma_t(x)$ определяет среднеквадратичное отклонение, отражающее степень неопределенности в текущей точке. Свободный параметр $\kappa > 0$ настраивается исследователем вручную: его увеличение смещает фокус алгоритма на глобальный поиск в областях с высокой дисперсией, тогда как уменьшение заставляет систему детально сканировать окрестности уже известных экстремумов.

Теоретическая сходимость такой схемы обеспечивается за счет сочетания стохастического поиска (через эволюционные операторы мутации и скрещивания) и детерминированного разбиения пространства по принципу алгоритма DIRECT. Это позволяет популяции эффективно выходить из локальных минимумов и гарантирует, что при увеличении числа итераций найденное решение будет асимптотически приближаться к истинному глобальному оптимуму.

Разработанный методологический комплекс гарантирует математическую строгость процедур глобальной оптимизации и вычислительную устойчивость программного инструментария при параметрической настройке архитектур машинного обучения в мультиразмерных пространствах признаков. В рамках верификации предложенного подхода осуществлен сравнительный анализ четырех поисковых стратегий: случайного сканирования (Random Search), канонического генетического алгоритма, байесовской оптимизации на базе среды Optuna и авторского гибридного

метода EA-SM. Динамика взаимодействия функциональных блоков, а именно контура активного обучения и модифицированного эволюционного оператора, наглядно отражена в структурно-логической схеме (см. рис. 1).




Рис. 1. Блок-схема разработанного алгоритма EA-SM
Fig. 1. Block diagram of the developed EA-SM algorithm

Структурная организация алгоритма EA-SM, отображенная на рис. 1, основана на циклической интеграции механизмов стохастического поиска и аппроксимационного моделирования. Взаимодействие между блоком суррогатного моделирования и эволюционным оператором минимизирует вычислительную нагрузку на целевую функцию за счет фильтрации неперспективных решений на ранних этапах итерации. Модуль активного обучения обеспечивает направленное уточнение модели в зонах с высокой неопределенностью, что гарантирует баланс между исследованием пространства и локальной оптимизацией. Для количественной оценки

результативности разработанной архитектуры проведено сравнительное тестирование на задачах классификации стохастических объектов (см. табл. 1).

Таблица 1

Сравнение точности классификации стохастических объектов

Table 1

Comparison of classification accuracy of stochastic objects

Алгоритм	Итераций 50	Итераций 100	Итераций 200	Время (сек.)
Random Search	0,821	0,835	0,842	450
Standard GA	0,834	0,856	0,861	1200
Bayesian (Optuna)	0,852	0,868	0,875	800
Proposed EA-SM	0,865	0,879	0,884	650

Анализ данных таблицы 1 показывает, что предложенный метод достигает более высоких показателей точности при меньших временных затратах по сравнению со стандартным генетическим алгоритмом. Сокращение времени достигается за счет того, что большинство особей в популяции оцениваются по суррогату $\hat{f}$, а трудоемкое вычисление f производится только для наиболее перспективных кандидатов. Дальнейшая проверка работоспособности алгоритма проводилась в условиях многокритериальной оптимизации гиперпараметров для определения устойчивости получаемых решений. В таблице 2 отражена устойчивость алгоритма.

Таблица 2

Параметры сходимости для многокритериальной оптимизации гиперпараметров

Table 2

Convergence parameters for multi-objective hyperparameter optimization

Стратегия	Среднее IGD	Медиана	СКО
NSGA-II	0,0452	0,0441	0,0031
MOEA/D	0,0438	0,0429	0,0028
Hybrid EA-SM	0,0381	0,0375	0,0019

Сравнительный анализ метрик, систематизированных в таблице 2, позволяет верифицировать вычислительное превосходство разработанного алгоритма Hybrid EA-SM над классическими метаэвристическими схемами NSGA-II и MOEA/D. В частности, интегральная оценка качества аппроксимации по критерию IGD (Inverted Generational Distance) для Hybrid EA-SM локализована на уровне 0,0381. Данное значение качественно превосходит аналогичные параметры альтернативных стратегий - 0,0452 у NSGA-II и 0,0438 у MOEA/D, - детерминируя существенно более высокую плотность приближения генерируемых решений к теоретическому фронту Парето. Устойчивость поисковой процедуры экстраполируется и на медианные значения критерия: фиксация медианы Hybrid EA-SM в точке 0,0375 (против 0,0441 и 0,0429 у базовых алгоритмов) нивелирует гипотезу о деструктивном влиянии стохастических аномалий или случайных выбросов на финальную сходимость. Дополнительным маркером вычислительной стабильности предложенного гибрида выступает динамика среднеквадратичного отклонения (СКО), минимизированного до 0,0019, тогда как для референтных подходов дисперсия признака колеблется в пределах 0,0031 (NSGA-II) и 0,0028 (MOEA/D).

Столь низкая вариативность СКО выступает прямым следствием робастности гибридной архитектуры в многокритериальных пространствах признаков. Локальное сужение интервала неопределенности при идентификации экстремумов позволяет оптимизировать процедуру поиска векторов гиперпараметров, сводя к минимуму дисперсию результатов между итерациями. Физико-математическая валидность превосходства Hybrid EA-SM детерминирована синергетическим эффектом имплементации адаптивных суррогатных моделей в контур эволюционных операторов, что обеспечивает целенаправленный дрейф популяции агентов к глобальной области оптимума.

Перенос описанного оптимизационного инструментария на уровень глубоких нейросетевых структур (в частности, при настройке конфигураций трансформеров) накладывает дополнительные требования к учету латентных временных зависимостей, специфика которых отражена в экспликации таблицы 3

Таблица 3

Ошибка прогнозирования (sMAPE) для моделей временных рядов

Table 3

Forecast error (sMAPE) for time series models

Модель	Без оптимизации	Random Search	Optuna	EA-SM
Beer Production Data	12,4%	10,1%	8,7%	8,2%
Industry 4.0 Tasks	15,8%	13,2%	11,5%	10,9%

Эмпирические результаты, систематизированные в таблице 3, позволяют квантифицировать вычислительный эффект от интеграции разработанного гибридного алгоритма в контур параметрической настройки прогностических архитектур. Так, в ходе апробации на верификационном массиве Beer Production Data применение EA-SM обеспечило снижение симметричной средней абсолютной процентной ошибки (sMAPE) до 8,2%, тогда как базовая конфигурация без предварительной оптимизации демонстрировала уровень в 12,4%. Достигнутый показатель сходимости качественно превосходит результаты, полученные посредством случайного поиска (Random Search, 10,1%) и байесовского аппарата среды Optuna (8,7%), что верифицирует прецизионный характер сканирования подпространства коэффициентов регуляризации.

Схожий вектор динамики векторов погрешности идентифицирован при моделировании процессов в рамках сценариев Industry 4.0 Tasks: здесь стартовый уровень sMAPE (15,8%) удалось минимизировать до 10,9%. Зафиксированный в данном эксперименте локальный зазор в 0,6% между финальными оценками EA-SM и Optuna выступает весомым аргументом в пользу селективной мощности эволюционного поиска при детерминации топологий трансформеров, критически чувствительных к латентным временным интервалам. Систематический регресс ошибки sMAPE, прослеживаемый на всей выборке тестовых задач, подтверждает гипотезу об инвариантности и высокой адаптивной способности предложенного метода к нестационарным динамическим характеристикам исследуемых временных рядов.

Минимизация sMAPE в рамках метаэвристики EA-SM обусловлена ее способностью к экспликации нелинейных, неочевидных интервалов регуляризации, латентно форсирующих сходимость алгоритмов тематического моделирования. Статистическая валидность зафиксированных улучшений строго верифицирована непараметрическим критерием знаковых рангов Вилкоксона (уровень значимости $p < 0,05$ выдержан во всех контрольных итерациях). В контексте масштабируемости разработанного подхода фундаментальное прикладное значение приобретает экспресс-анализ утилизации вычислительных мощностей при экспоненциальном расширении размерности оптимизируемой среды, подробная визуализация которого приведена в таблице 4.

Таблица 4

Ресурсная эффективность (среднее количество обращений к полной модели)

Table 4

Resource efficiency (average number of calls to the full model)

Размерность $\mathcal{H}$	Метод DIRECT	Optuna	EA-SM
$d = 1$	12	10	8
$d = 2$	35	24	18
$d = 3$	68	42	32
$d = 4$	110	65	52
$d = 5$	150	85	70
$d = 6$	215	115	92
$d = 7$	280	142	114

d = 8	355	175	136
d = 9	440	210	162
d = 10	530	250	188
d = 11	615	285	210
d = 12	690	310	225
d = 13	760	335	238
d = 14	810	350	242
d = 15	840	320	245
d = 16	920	360	275
d = 17	1040	410	310
d = 18	1180	465	345
d = 19	1350	520	385
d = 20	1510	580	420
d = 21	1680	640	460
d = 22	1840	695	505
d = 23	1990	740	545
d = 24	2120	785	580
d = 25	2240	830	610
d = 26	2310	870	635
d = 27	2390	900	655
d = 28	2450	925	670
d = 29	2480	940	675
d = 30	2500	950	680

Эмпирические оценки, консолидированные в таблице 4, позволяют верифицировать устойчивый характер превосходства разработанного метода EA-SM в контексте минимизации накладных вычислительных расходов при деструктивном масштабировании размерности пространства поиска. Так, в базисной конфигурации минимальной размерности ($d=1$) процедура EA-SM требует выполнения всего 8 итерационных обращений к целевой функции, перекрывая по эффективности альтернативные схемы Optuna и DIRECT, затрачивающие 10 и 12 вычислительных актов соответственно. Экспоненциальное расширение пула оптимизируемых гиперпараметров до уровня $d=10$ делает зафиксированный разрыв в утилизации ресурсов еще более выраженным: алгоритм EA-SM локализует область оптимума за 188 шагов, существенно опережая байесовский поиск Optuna (250 шагов) и более чем вдвое превосходя детерминированную стратегию DIRECT (530 шагов).

Стабильность обнаруженной тенденции подтверждается и при увеличении размерности признаков пространства до среднего уровня ($d=20$). В рамках данного сценария авторский метод сохраняет высокую скорость сходимости: объем итерационного пула жестко ограничен 420 обращениями к целевой функции. Для сравнения, байесовский поиск во фреймворке Optuna требует проведения 580 вычислительных экспериментов, а детерминированное геометрическое расщепление областей в алгоритме DIRECT приводит к экспоненциальному росту нагрузки, достигающему 1510 шагов. В критических условиях высокой размерности ($d=30$) предложенный гибрид EA-SM существенно снижает кумулятивные затраты процессорного времени. Так, для полной локализации оптимума системе требуется не более 680 вычислений, тогда как эффективность Optuna падает (950 шагов), а алгоритм DIRECT демонстрирует вычислительный взрыв, затрачивая до 2500 целевых обращений.

Факторы, обуславливающие сохранение высокой аппроксимирующей способности схемы при жестком лимитировании доступного бюджета вычислений, детально верифицируются посредством анализа плотности распределения остатков моделирования (см. рис. 2).




Рис. 2. Распределение ошибки аппроксимации суррогата
Fig. 2. Distribution of the surrogate approximation error

Характер распределения остатков (рис. 2) указывает на пространственную неоднородность точности аппроксимации с локализацией минимальной дисперсии погрешности в окрестностях целевых экстремумов. Данное свойство предопределяет корректность финального оптимизационного выбора. Высокая селективная точность суррогата в окрестностях экстремальных значений снижает риск пропуска глобального минимума целевого функционала, что позволяет существенно сократить общий объем поисковых вычислений без потери достоверности результатов.

ЗАКЛЮЧЕНИЕ

В ходе выполненного исследования предложен метод преодоления вычислительной трудоемкости, характерной для процедур параметрической настройки сложных нейросетевых архитектур в системах AutoML при дефиците доступных ресурсов. На основе разработанного гибридного подхода EA-SM удалось объединить поисковый потенциал стохастических эвристик с эффективностью байесовской оптимизации для оптимизации целевых функций класса «черный ящик».

Теоретические результаты работы связаны с формированием единой оптимизационной схемы, сочетающей глобальный поиск за счет эволюционных операторов с локальным уточнением решений посредством адаптивных гауссовских суррогатных моделей. Использование регуляризации Тихонова позволило исключить риски сингулярности и обусловленной ею вычислительной деградации ковариационных матриц, обеспечив устойчивость алгоритма при росте размерности признакового пространства. В рамках численных экспериментов подтверждено, что предложенная схема обеспечивает не только сокращение числа прямых вычислений целевой

функции, но и селективную концентрацию поисковых точек в окрестностях Парето-фронта и локальных зон минимизации.

Практическая применимость подхода верифицирована в ходе тестирования на задачах анализа нестационарных временных рядов в контуре Industry 4.0. Алгоритм EA-SM подтвердил устойчивость к стохастическому шуму и наличию аномалий в выборках. В качестве дальнейшего развития темы исследования планируется модификация разработанного математического ядра для решения задач многокритериальной дискретно-непрерывной оптимизации, а также его интеграция в программные комплексы распределенного автоматического проектирования систем мониторинга.

Список литературы

1. Акопов А.С. Моделирование и оптимизация стратегий принятия индивидуальных решений в многоагентных социально-экономических системах с использованием машинного обучения // Бизнес-информатика. 2023. Т. 17. № 2. С. 7–19.
2. Анафиев А.С., Карюк А.С. Обзор подходов к решению задачи оптимизации гиперпараметров для алгоритмов машинного обучения // Таврический вестник информатики и математики. 2022. № 2(55). С. 30–37.
3. Горбунов С.М., Становов В.В. Эволюционный алгоритм многокритериальной оптимизации с суррогатными моделями машинного обучения // Вестник Московского государственного технического университета им. Н.Э. Баумана. Серия «Приборостроение». 2025. № 2(151). С. 48–62.
4. Клейнер С.Г. Исследование точности решения задачи оптимизации гиперпараметров с помощью нейронной сети // Вестник науки. 2025. Т. 3. № 6 (87). С. 1785–1791.
5. Матвеев А.Н. Инструменты построения моделей машинного обучения // E-Scio. 2023. № 6(81). С. 71–77.
6. Тимофеев А.В. Метод выбора гиперпараметров в задачах машинного обучения для классификации стохастических объектов // Научно-технический вестник информационных технологий, механики и оптики. 2020. Т. 20. № 5. С. 667–676.
7. Трунов Е.Е. Алгоритм обнаружения аномального поведения пользователей автоматизированных систем на основе методов машинного обучения // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2025. № 4. С. 33–42.
8. Усова М.А., Лебедев И.Г., Штанюк А.А., Баркалов К.А. Алгоритм глобальной оптимизации для настройки гиперпараметров методов машинного обучения // Проблемы информатики. 2025. № 4 (69). С. 52–72.
9. Ходорченко М.А., Бутаков Н.А., Насонов Д.А., Фирулик М.Ю. Программный фреймворк для оптимизации гиперпараметров тематических моделей с аддитивной регуляризацией // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 1. С. 112–120.
10. Abdallah M. AutoForecast: Automatic Time-Series Forecasting Model Selection // Proceedings of the 31st ACM International Conference on Information & Knowledge Management (CIKM '22). 2022. P. 5–14.
11. Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A Next-Generation Hyperparameter Optimization Framework // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019. P. 2623–2631.
12. Ansari A.F. Chronos: Learning the Language of Time Series // arXiv preprint arXiv:2403.07815. 2024. / Christ M. Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package) // Neurocomputing. 2018. Т. 307. P. 72–77.
13. Audet C., Batailly A., Kojtych S. Escaping unknown discontinuous regions in blackbox optimization // SIAM Journal on Optimization. 2022. Т. 32. № 3. P. 1843–1870.
14. Candelieri A. Sequential model based optimization of partially defined functions under unknown constraints // Journal of Global Optimization. 2019. Т. 73. № 2. P. 281–303.
15. Conrad F. AutoML Applied to Time Series Analysis Tasks in Production Engineering // Procedia Computer Science. 2024. Т. 232. P. 849–860.
16. Filippou K., Aifantis G., Papakostas G.A., Tsekouras G.E. Structure learning and hyperparameter optimization using an automated machine learning (AutoML) pipeline // Information. 2023. Т. 14. № 4. P. 232.
17. Paulavicius R., Sergeyev Y.D., Kvasov D.E., Zilinskas J. Globally-biased BIRECT algorithm with local accelerators for expensive global optimization // Expert Systems with Applications. 2020. Т. 144. P. 113052.

18. Sergeyev Y.D., Kvasov D.E., Mukhametzhano M.S. On the efficiency of nature-inspired metaheuristics in expensive global optimization with limited budget // *Scientific Reports*. 2018. T. 8. № 1. P. 453.
19. Stripinis L., Paulavicius R. A new DIRECT-GLh algorithm for global optimization with hidden constraints // *Optimization Letters*. 2021. T. 15. № 6. P. 1865–1884.
20. Sun Y., Yen G., Yi Z. IGD indicator-based evolutionary algorithm for manyobjective optimization problems // *IEEE Transactions on Evolutionary Computation*. 2019. T. 23. № 2. P. 173–187.
21. Truong A. Towards Automated Machine Learning: Evaluation and Comparison of AutoML Approaches and Tools // *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*. 2019. P. 1471–1479.
22. Wang H., Jin Y., Doherty J. Committee-based active learning for surrogate-assisted particle swarm optimization of expensive problems // *IEEE Transactions on Cybernetics*. 2017. T. 47. № 9. P. 2664–2677.
23. Waring J., Lindvall C., Umeton R. Automated machine learning: Review of the state-of-the-art and opportunities for healthcare // *Artificial Intelligence in Medicine*. 2020. T. 104. P. 101822.
24. Xu N. Time Series Analysis on Monthly Beer Production in Australia // *Highlights in Science, Engineering and Technology*. 2024. T. 94. P. 392–401.

References

1. Akopov A.S. Modeling and Optimization of Individual Decision-Making Strategies in Multi-Agent Socio-Economic Systems Using Machine Learning // *Business Informatics*. 2023. Vol. 17. No. 2. pp. 7–19.
2. Anafiyev A.S., Karyuk A.S. Review of Approaches to Solving the Problem of Hyperparameter Optimization for Machine Learning Algorithms // *Tavrisheskiy Vestnik Informatics and Mathematics*. 2022. No. 2(55). pp. 30–37.
3. Gorbunov S.M., Stanovov V.V. Evolutionary Algorithm for Multicriteria Optimization with Surrogate Machine Learning Models // *Bulletin of the Bauman Moscow State Technical University. Series «Instrument Engineering»*. 2025. No. 2 (151). pp. 48–62.
4. Kleiner S.G. Study of the accuracy of the solution of the hyperparameter optimization problem using a neural network // *Vestnik nauki*. 2025. Vol. 3. No. 6 (87). Pp. 1785–1791.
5. Matveev A.N. Tools for constructing machine learning models // *E-Scio*. 2023. No. 6 (81). Pp. 71–77.
6. Timofeev A.V. Method for selecting hyperparameters in machine learning problems for classifying stochastic objects // *Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*. 2020. Vol. 20. No. 5. Pp. 667–676.
7. Trunov E. E. Algorithm for detecting anomalous behavior of users of automated systems based on machine learning methods // *Bulletin of Astrakhan State Technical University. Series: Control, Computer Engineering, and Informatics*. 2025. No. 4. pp. 33–42.
8. Usova M. A., Lebedev I. G., Shtanyuk A. A., Barkalov K. A. A global optimization algorithm for tuning hyperparameters of machine learning methods // *Problems of Informatics*. 2025. No. 4 (69). pp. 52–72.
9. Khodorchenko M. A., Butakov N. A., Nasonov D. A., Firulik M. Yu. A software framework for optimizing hyperparameters of topic models with additive regularization // *Scientific and Technical Bulletin of Information Technologies, Mechanics, and Optics*. 2023. Vol. 23. No. 1. pp. 112–120.
10. Abdallah M. AutoForecast: Automatic Time-Series Forecasting Model Selection // *Proceedings of the 31st ACM International Conference on Information & Knowledge Management (CIKM '22)*. 2022. P. 5–14.
11. Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A Next-Generation Hyperparameter Optimization Framework // *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2019. P. 2623–2631.
12. Ansari A.F. Chronos: Learning the Language of Time Series // *arXiv preprint arXiv:2403.07815*. 2024. / Christ M. Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package) // *Neurocomputing*. 2018. T. 307. P. 72–77.
13. Audet C., Batailly A., Kojtych S. Escaping unknown discontinuous regions in blackbox optimization // *SIAM Journal on Optimization*. 2022. T. 32. № 3. P. 1843–1870.
14. Candelieri A. Sequential model based optimization of partially defined functions under unknown constraints // *Journal of Global Optimization*. 2019. T. 73. № 2. P. 281–303.
15. Conrad F. AutoML Applied to Time Series Analysis Tasks in Production Engineering // *Procedia Computer Science*. 2024. T. 232. P. 849–860.
16. Filippou K., Aifantis G., Papakostas G.A., Tsekouras G.E. Structure learning and hyperparameter optimization using an automated machine learning (AutoML) pipeline // *Information*. 2023. T. 14. № 4. P. 232.

17. Paulavicius R., Sergeyev Y.D., Kvasov D.E., Zilinskas J. Globally-biased BIRECT algorithm with local accelerators for expensive global optimization // Expert Systems with Applications. 2020. T. 144. P. 113052.
18. Sergeyev Y.D., Kvasov D.E., Mukhametzhanov M.S. On the efficiency of nature-inspired metaheuristics in expensive global optimization with limited budget // Scientific Reports. 2018. T. 8. № 1. P. 453.
19. Stripinis L., Paulavicius R. A new DIRECT-GLh algorithm for global optimization with hidden constraints // Optimization Letters. 2021. T. 15. № 6. P. 1865–1884.
20. Sun Y., Yen G., Yi Z. IGD indicator-based evolutionary algorithm for manyobjective optimization problems // IEEE Transactions on Evolutionary Computation. 2019. T. 23. № 2. P. 173–187.
21. Truong A. Towards Automated Machine Learning: Evaluation and Comparison of AutoML Approaches and Tools // 2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI). 2019. P. 1471–1479.
22. Wang H., Jin Y., Doherty J. Committee-based active learning for surrogate-assisted particle swarm optimization of expensive problems // IEEE Transactions on Cybernetics. 2017. T. 47. № 9. P. 2664–2677.
23. Waring J., Lindvall C., Umeton R. Automated machine learning: Review of the state-of-the-art and opportunities for healthcare // Artificial Intelligence in Medicine. 2020. T. 104. P. 101822.
24. Xu N. Time Series Analysis on Monthly Beer Production in Australia // Highlights in Science, Engineering and Technology. 2024. T. 94. P. 392–401.

Зарипов Евгений Андреевич, ассистент кафедры инструментального и прикладного программного обеспечения, Российский технологический университет МИРЭА, г. Москва, Россия

Лазаренко Сергей Александрович, студент кафедры инструментального и прикладного программного обеспечения, Российский технологический университет МИРЭА, г. Москва, Россия

Zaripov Evgeny Andreevich, Assistant of the Department of Instrumental and Applied Software, Russian Technological University MIREA, Moscow, Russia

Lazarenko Sergey Alexandrovich, Student of the Department of Instrumental and Applied Software, Russian Technological University MIREA, Moscow, Russia

КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ COMPUTER SIMULATION

УДК 004.75

DOI: 10.18413/2518-1092-2026-11-2-0-10

Воскобойников И.С.
Гвоздевский И.Н.
Булгаков В.Д.

**МЕТОД АДАПТИВНОГО ФОРМИРОВАНИЯ БЛОКОВ
И ИНДЕКСАЦИИ НЕСТРУКТУРИРОВАННЫХ ДАННЫХ
В ДЕЦЕНТРАЛИЗОВАННЫХ СИСТЕМАХ ХРАНЕНИЯ**

Белгородский государственный технологический университет им. В.Г. Шухова
ул. Костюкова, 46, г. Белгород, 308012, Россия

e-mail: ilia.voskoboinikov@mail.ru

Аннотация

В статье рассматривается задача обработки и индексирования неструктурированных текстовых данных в децентрализованных системах хранения. Проведён анализ существующих подходов, основанных на статических параметрах формирования блоков, выявлены их ограничения, связанные с отсутствием учёта динамических характеристик распределённой среды, что приводит к увеличению сетевой нагрузки и снижению эффективности поиска.

Предложен метод адаптивного формирования блоков и индексирования данных, учитывающий интенсивность входного потока, уровень загрузки сети и количество активных узлов. Описана архитектура системы, включающая модули предобработки, агрегации данных, индексирования и распределённого хранения на основе распределённых хеш-таблиц. Разработана математическая модель и алгоритм, обеспечивающие динамическое управление параметрами формирования блоков.

Проведён теоретический анализ работы алгоритма, показано влияние ключевых параметров системы на процессы формирования блоков. Выполнено сравнение с фиксированным методом, продемонстрированы преимущества адаптивного подхода с точки зрения снижения сетевых издержек, повышения масштабируемости и устойчивости к изменению нагрузки.

Работа может быть использована при разработке распределённых систем хранения, поисковых платформ и систем потоковой обработки данных. Полученные результаты создают основу для дальнейших исследований адаптивных и гибридных методов обработки неструктурированных данных в децентрализованных средах.

Ключевые слова: неструктурированные данные; децентрализованные системы хранения; адаптивное формирование блоков; распределённая индексация; DHT; обработка текстовых данных; масштабируемость; оптимизация

Для цитирования: Воскобойников И.С., Гвоздевский И.Н., Булгаков В.Д. Метод адаптивного формирования блоков и индексации неструктурированных данных в децентрализованных системах хранения // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 121-134. DOI: 10.18413/2518-1092-2026-11-2-0-10

Voskoboinikov I.S.
Gvozdevsky I.N.
Bulgakov V.D.

METHOD OF ADAPTIVE BLOCK FORMATION AND INDEXING OF UNSTRUCTURED DATA IN DECENTRALIZED STORAGE SYSTEMS

Belgorod State Technological University named after V.G. Shukhov
46 Kostyukova St., Belgorod, 308012, Russia

e-mail: ilia.voskoboinikov@mail.ru

Abstract

The paper addresses the problem of processing and indexing unstructured textual data in decentralized storage systems. An analysis of existing approaches based on static block formation parameters is conducted, revealing their limitations related to the lack of consideration of dynamic characteristics of distributed environments, which leads to increased network overhead and reduced search efficiency.

An adaptive method for block formation and data indexing is proposed, taking into account input data rate, network load, and the number of active nodes. The system architecture is described, including modules for data preprocessing, aggregation, indexing, and distributed storage based on distributed hash tables. A mathematical model and an algorithm are developed to provide dynamic control of block formation parameters.

A theoretical analysis of the proposed algorithm is performed, demonstrating the influence of key system parameters on block formation. A comparison with a fixed block formation method is presented, showing the advantages of the adaptive approach in terms of reduced network costs, improved scalability, and robustness under varying load conditions.

The proposed method can be applied in the design of distributed storage systems, decentralized search platforms, and stream processing systems. The results provide a foundation for further research on adaptive and hybrid methods for processing unstructured data in decentralized environments.

Keywords: unstructured data; decentralized storage systems; adaptive block formation; distributed indexing; DHT; text processing; scalability; optimization

For citation: Voskoboinikov I.S., Gvozdevsky I.N., Bulgakov V.D. Method of Adaptive Block Formation and Indexing of Unstructured Data in Decentralized Storage Systems // Research result. Information technologies. – T.11, №2, 2026. – P. 121-134. DOI: 10.18413/2518-1092-2026-11-2-0-10

ВВЕДЕНИЕ

Существующие методы обработки и поиска неструктурированных данных, как правило, разрабатывались для централизованных систем и предполагают наличие глобального индекса, централизованных вычислительных ресурсов и стабильной инфраструктуры хранения [7]. В условиях децентрализации такие предпосылки не выполняются, что требует адаптации классических подходов к новым архитектурным ограничениям. В частности, методы распределённой индексации позволяют частично решить проблему поиска данных за счёт размещения индексных структур в распределённой среде [8]. Однако такие подходы, как правило, используют статические параметры обработки и не учитывают динамику изменения состояния сети. Однако такие подходы, как правило, используют статические параметры обработки и не учитывают динамику изменений состояния сети.

В ряде работ, посвящённых децентрализованным системам хранения, основной акцент сделан на вопросах функционирования базовой инфраструктуры – в частности, рассматриваются алгоритмы маршрутизации в одноранговых сетях, механизмы репликации данных, а также подходы к обеспечению их целостности и согласованности [9, 10].

При этом аспекты, связанные с адаптацией параметров обработки и индексирования неструктурированных данных, как правило, рассматриваются эпизодически и не образуют целостного методического подхода.

Анализ существующих решений показывает, что в них отсутствует единый механизм, позволяющий учитывать изменения характеристик системы – таких как интенсивность поступления данных, текущая загрузка сети и изменение числа активных узлов – при формировании блоков и построении индексных структур.

На практике это приводит к ряду эффектов: увеличению объёма сетевого взаимодействия, росту задержек при выполнении поисковых операций и снижению эффективности использования ресурсов распределённой среды. Особенно явно данные проблемы проявляются в условиях нестабильной нагрузки, когда параметры системы изменяются во времени.

В связи с этим возникает необходимость разработки подходов, ориентированных на динамическую настройку параметров обработки данных. Речь идёт о переходе от фиксированных схем к моделям, способным изменять своё поведение в зависимости от текущего состояния распределённой системы.

Целью работы является разработка метода адаптивного формирования блоков и индексации неструктурированных данных в децентрализованных системах хранения, обеспечивающего снижение сетевой нагрузки и повышение эффективности выполнения поисковых операций.

Следует отметить, что большинство современных решений ориентированы на оптимизацию отдельных аспектов (хранение, маршрутизация), тогда как комплексные методы адаптивного управления процессами обработки данных остаются недостаточно разработанными.

Научная новизна работы заключается в разработке адаптивной модели формирования блоков, учитывающей одновременно интенсивность потока данных, загрузку сети и количество активных узлов, а также в интеграции данной модели с механизмами распределённой индексации в DHT-системах.

АРХИТЕКТУРА СИСТЕМЫ

В рамках исследования рассматривается децентрализованная система обработки и хранения неструктурированных данных, построенная на основе одноранговой (peer-to-peer) сети с использованием распределённой хеш-таблицы (DHT). Архитектура системы ориентирована на обеспечение масштабируемости, отказоустойчивости и эффективной обработки текстовых данных в условиях динамически изменяющейся сетевой среды [4–6].

Предлагаемая архитектура включает в себя совокупность взаимодействующих компонентов, реализующих полный цикл обработки данных – от их поступления до индексирования и размещения в распределённом хранилище. В отличие от традиционных централизованных систем, каждый узел сети выполняет как функции хранения, так и функции обработки данных, что соответствует принципам децентрализованных вычислений [9].

В архитектуре выделяются следующие функциональные модули:

1. Модуль приёма данных (Data Ingestion Module)

Данный модуль обеспечивает поступление неструктурированных текстовых данных в систему из внешних источников. Источниками могут выступать пользовательские запросы, потоки данных, файловые системы или распределённые хранилища. Поток данных характеризуется интенсивностью поступления (классическая модель потока заявок [14]), которая может быть описана как:

$$\lambda(t) = \frac{dN(t)}{dt},$$

где

$\lambda(t)$ – интенсивность поступления данных (документов/единицу времени);

$N(t)$ – кумулятивное количество поступивших документов к моменту времени t ;

t – время.

2. Модуль предобработки данных (Preprocessing Module)

На данном этапе осуществляется преобразование неструктурированных текстовых данных в форму, пригодную для индексирования. Предобработка включает токенизацию, нормализацию,

удаление стоп-слов и лемматизацию, что соответствует классическим подходам обработки текстовой информации [7]. Результатом работы модуля является множество термов:

$$T(D_j) = \{t_{j1}, t_{j2}, \dots, t_{jm_j}\},$$

где

D_j – j -й документ;

$T(D_j)$ – множество термов документа;

t_{ji} – i -й терм документа D_j ;

m_j – количество термов в документе.

3. Модуль адаптивного формирования блоков (Adaptive Block Formation Module)

Ключевым элементом предлагаемой архитектуры является модуль формирования блоков данных, обеспечивающий агрегирование отдельных документов в блоки перед их индексированием и размещением в системе. Блок определяется как:

$$B_k = \{D_1, D_2, \dots, D_k\},$$

где

B_k – k -й сформированный блок;

D_i – i -й документ;

k – количество документов в блоке.

В отличие от существующих подходов, где размер блока фиксирован, в данной работе предполагается использование адаптивного механизма, учитывающего текущее состояние системы (нагрузку сети, интенсивность поступления данных и количество узлов).

4. Модуль индексирования (Indexing Module)

После формирования блока выполняется построение индексной структуры, обеспечивающей эффективный поиск данных. Индекс блока формируется на основе объединения термов входящих в него документов:

$$I(B_k) = \bigcup_{i=1}^k T(D_i),$$

где

$I(B_k)$ – индекс блока;

$T(D_i)$ – множество термов документа.

Полученный индекс сопоставляется с идентификатором блока, формируемым с использованием хеш-функции:

$$CID_k = H(B_k),$$

где

CID_k – контент-адресуемый идентификатор блока;

$H(\cdot)$ – криптографическая хеш-функция [4],

B_k – k -й сформированный блок.

5. Модуль распределённого хранения (Distributed Storage Module)

Хранение блоков и соответствующих индексных структур осуществляется в распределённой хеш-таблице. Каждому ключу (CID) сопоставляется узел сети, ответственный за его хранение. Распределение данных выполняется на основе метрики расстояния (например, XOR-метрики в алгоритме Kademlia) [5]. Функция размещения может быть представлена в виде:

$$Node(CID_k) = \arg \min_{n \in \mathcal{N}} d(CID_k, n)$$

где

$\mathcal{N}$ – множество узлов сети;

n – конкретный узел;

$d(\cdot, \cdot)$ – метрика расстояния (например XOR);

$Node(CID_k)$ – узел, где хранится блок.

6. Модуль поиска (Query Processing Module)

Поиск данных осуществляется посредством обращения к распределённому индексу. Запрос преобразуется в набор термов, после чего выполняется поиск соответствующих блоков в DHT. Результатом является множество идентификаторов:

$$R(Q) = \{CID_1, CID_2, \dots, CID_p\}$$

где

Q – поисковый запрос;

$R(Q)$ – результат поиска;

CID_p – найденные блоки;

p – количество найденных блоков.

Общую архитектуру системы можно представить в виде следующей схемы (см.рисунок 1).




Рис. 1. Общая архитектура системы
Fig. 1. General architecture of the system

В отличие от существующих решений, предложенная архитектура обладает следующими характеристиками:

- Отсутствие централизованного узла управления.
- Совмещение функций хранения и обработки на уровне узлов.
- Использование контент-адресуемого хранения.

- Введение модуля адаптивного формирования блоков как ключевого элемента системы.
- Возможность динамической настройки параметров обработки данных.

Предложенная архитектура может быть реализована как поверх существующих протоколов, таких как Kademlia или Chord, без существенной модификации их базовых механизмов маршрутизации.

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ АДАПТИВНОГО ФОРМИРОВАНИЯ БЛОКОВ

В условиях децентрализованных систем хранения эффективность обработки неструктурированных данных во многом определяется параметрами формирования блоков и стратегией их индексирования. В традиционных подходах размер блока и частота его формирования задаются статически, что не учитывает динамику изменения характеристик системы, таких как интенсивность поступления данных, загрузка сети и количество активных узлов [9, 12]. Это приводит к неэффективному использованию ресурсов и увеличению времени отклика системы.

В работе предлагается математическая модель адаптивного формирования блоков, основанная на учёте динамических параметров распределённой среды. Подобные подходы к адаптивному управлению параметрами системы рассматриваются в работах по динамическому распределению ресурсов [11]. Для формализации задачи вводится следующий набор параметров:

- $\lambda(t)$ – интенсивность поступления данных;
- $L(t) \in [0, 1]$ – уровень загрузки сети;
- t_{acc} – время накопления блока;
- V_k – формируемый блок данных;
- $|V_k|$ – размер блока (количество документов);
- V_{max} – максимально допустимый размер блока;
- $N(t)$ – количество активных узлов в сети момент времени t ;
- T_{max} – максимально допустимое время формирования блока.

В рамках предлагаемой модели предполагается, что функции $\lambda(t)$, $L(t)$, $N(t)$ являются кусочно-непрерывными и могут оцениваться на основе данных мониторинга распределённой системы. Следует отметить, что точность их определения зависит от используемых механизмов сбора метрик и может изменяться во времени.

Указанные параметры одновременно характеризуют как свойства входного потока данных, так и текущее состояние сети. Формирование блока осуществляется при выполнении одного из следующих условий:

$$|V_k| \geq V_{max} \vee t_{acc} \geq T_{max}.$$

Подобное условие соответствует широко применяемым стратегиям буферизации в системах потоковой обработки данных, однако в данном случае она используется в качестве базового ограничения.

В отличие от фиксированных подходов, в работе предлагается определять размер блока как функцию от динамических параметров системы:

$$V_{opt}(t) = \alpha * \frac{\lambda(t)}{L(t) + \varepsilon} * N(t),$$

где

$V_{opt}(t)$ – оптимальный размер блока;

α – коэффициент масштабирования;

ε – малая положительная константа, предотвращающая деления на ноль;

$T(t)$ – количество узлов сети.

Предложенная функция отражает интуитивно ожидаемое поведение системы: при увеличении интенсивности входного потока размер блока возрастает, тогда как рост загрузки сети приводит к его уменьшению. Увеличение числа узлов, напротив, позволяет системе обрабатывать более крупные блоки за счёт распределения нагрузки.

Для учета времени формирования блока, вводится следующая функция:

$$T_{\text{opt}}(t) = \beta * \frac{1}{\lambda(t)} * (1 + L(t)),$$

где

$T_{\text{opt}}(t)$ – оптимальное время формирования блока;

β – коэффициент масштабирования времени.

Она отражает поведение системы при различных режимах работы. При увеличении интенсивности входного потока интервал накопления сокращается, что позволяет быстрее формировать блоки. В условиях высокой сетевой нагрузки, напротив, допускается увеличение времени накопления, что снижает частоту передачи данных.

Процесс формирования блоков можно рассматривать с позиции минимизации совокупных затрат, включающих сетевые издержки и время поиска:

$$\min_{B_k} (C_{\text{net}}(B_k) + T_{\text{search}}(B_k)),$$

где

$C_{\text{net}}(B_k)$ – суммарные затраты сети;

$T_{\text{search}}(B_k)$ – время поиска данных.

В рамках принятой модели предполагается, что:

$$C_{\text{net}}(B_k) \sim |B_k| * \log N(t)$$

$$T_{\text{search}}(B_k) \sim \log |I(B_k)|,$$

где

$I(B_k)$ – индекс блока.

С учётом введённых зависимостей условия формирования блока принимают вид:

$$|B_k| \geq V_{\text{opt}}(t) \vee t_{\text{acc}} \geq T_{\text{opt}}(t).$$

Увеличение размера блока приводит к снижению сетевых издержек, однако одновременно усложняет процедуры поиска, что требует выбора компромиссного режима функционирования системы.

Следует отметить, что предложенная модель имеет ряд ограничений:

- параметры $\lambda(t)$, $L(t)$, $N(t)$ считаются известными и измеримыми;
- не учитывается семантическая структура данных;
- не рассматриваются задержки, связанные с репликацией данных;
- предполагается однородность узлов сети.

Несмотря на указанные ограничения, модель позволяет формализовать процесс адаптивного формирования блоков и может служить основой для дальнейших исследований.

АЛГОРИТМ АДАПТИВНОГО ФОРМИРОВАНИЯ БЛОКОВ И ИНДЕКСАЦИИ

Предложенная математическая модель адаптивного формирования блоков реализуется в виде алгоритма, обеспечивающего динамическое управление процессом агрегации данных и их индексирования в условиях децентрализованной среды. Алгоритм учитывает текущие характеристики системы, включая интенсивность входного потока данных, загрузку сети и количество активных узлов.

Алгоритм (см. рисунок 2) функционирует в потоковом режиме и включает следующие основные этапы:

1. Приём и буферизация входных данных;
2. Предобработка текстовой информации;
3. Динамическое формирование блока;
4. Проверка условий завершения блока;
5. Построение индексной структуры;
6. Хеширование блока и размещение в распределённой сети;
7. Обновление параметров системы.

В отличие от статических подходов, предложенный алгоритм реализует механизм адаптации параметров $B_{opt}(t)$ и $T_{opt}(t)$, определённых в предыдущем разделе.




Рис. 2. Алгоритм адаптивного формирования блоков и индексации
Fig. 2. Algorithm of adaptive block formation and indexing

Алгоритм имеет линейную вычислительную сложность $O(n)$ по числу обрабатываемых документов в блоке.

Предложенный алгоритм обладает следующими преимуществами:

- адаптация к динамике сети;
- снижение количества сетевых операций;
- уменьшение избыточной индексации;
- повышение масштабируемости системы;
- гибкость настройки параметров.

Ограничения алгоритма:

- требуется оценка параметров $\lambda(t)$, $L(t)$, $N(t)$;

- не учитываются приоритеты документов;
- отсутствует учёт семантической значимости данных;
- предполагается синхронность обновления параметров.

ДОКАЗАТЕЛЬСТВО КОРРЕКТНОСТИ РАБОТЫ АЛГОРИТМА

Для подтверждения работоспособности предложенного алгоритма адаптивного формирования блоков рассмотрим теоретический сценарий функционирования системы при различных параметрах входного потока и состояния сети.

Пусть: $\lambda(t)=50$ док/с, $L(t)=0.5$, $N(t)=10$, $\alpha=2$, $\beta=1$, $\varepsilon=0.01$

Расчёт адаптивного размера блока:

$$B_{opt}(t) = 2 * \frac{50}{0.5 + 0.01} * 10 \approx 1961.$$

Расчёт адаптивного времени:

$$T_{opt}(t) = 1 * \frac{1}{50} * (1 + 0.5) = 0.03$$

Формирование блока происходит при выполнении условий:

$$|B_k| \geq B_{opt}(t) \vee t_{acc} \geq T_{opt}(t).$$

За время $T_{opt}(t)$ в систему поступает документов:

$$\lambda(t) * T_{opt}(t) = 50 * 0.03 = 1.5 \approx 2$$

Следовательно:

- условие по времени выполняется быстрее;
- блок формируется по времени, а не по размеру.

Сценарий изменения нагрузки сети.

Пусть: $L(t)=0.9$.

Новый размер блока:

$$B_{opt}(t) = 2 * \frac{50}{0.9 + 0.01} * 10 \approx 1099.$$

Новое время:

$$T_{opt}(t) = 1 * \frac{1}{50} * (1 + 0.9) = 0.038.$$

Увеличение $L(t)$ приводит к уменьшению $B_{opt}(t)$ и увеличению $T_{opt}(t)$. Это соответствует целям алгоритма:

- снижение сетевой нагрузки;
- уменьшение объёма передаваемых данных.

Сценарий при увеличении числа узлов:

Пусть $N(t) = 20$, тогда новый размер блока:

$$B_{opt}(t) = 2 * \frac{50}{0.5 + 0.01} * 20 \approx 3921.$$

Полученный результат указывает на то, что при росте числа узлов система допускает формирование более крупных блоков. Это объясняется расширением доступных вычислительных и сетевых ресурсов, что позволяет перераспределять нагрузку между участниками сети.

Проведённые расчёты позволяют сделать следующие выводы:

- изменение входных параметров отражается на размере блока ожидаемым образом;
- достигается согласование между нагрузкой на сеть и производительностью обработки;
- поведение системы остаётся устойчивым при варьировании параметров.

С учётом полученных результатов можно считать, что предложенный алгоритм является пригодным для использования в распределённых средах, где характеристики нагрузки изменяются во времени.

СРАВНЕНИЕ С ФИКСИРОВАННЫМ МЕТОДОМ

В качестве базового подхода рассматривается метод с фиксированным размером блока:

$$V_{\text{fix}} = 1000,$$

где

V_{fix} – заранее заданный размер блока, не зависящий от параметров системы.

Подобные решения широко применяются на практике благодаря простоте реализации, однако их использование ограничено в условиях изменяющейся нагрузки. Отсутствие зависимости от параметров среды приводит к тому, что система не адаптируется к текущему состоянию сети и входного потока данных.

В предлагаемом методе размер блока определяется динамически и, в рассматриваемом примере, изменяется в диапазоне:

$$V_{\text{opt}}(t) \in [1099, 3921],$$

что зависит от значений $\lambda(t)$, $L(t)$ и $N(t)$.

Сравнительные характеристики двух подходов приведены в таблице.

Таблица

Сравнение методов

Table

Comparison of methods

Параметр	Фиксированный метод	Адаптивный метод
Размер блока	1000	1099-3921
Учет нагрузки $L(t)$	Нет	Да
Учет потока данных $\lambda(t)$	Нет	Да
Учет числа узлов $N(t)$	Нет	Да
Гибкость	Низка	Высокая
Адаптация к динамике среды	Отсутствует	Реализована
Сетевые издержки	Фиксированные, не оптимизируются	Снижаются за счет адаптации
Время отклика	Нестабильное при изменении нагрузки	Стабилизируется

По результатам проведенного сравнения можно увидеть, что фиксированный метод не учитывает изменение параметров распределенной системы, поэтому эффективность его применения будет зависеть от текущего состояния системы. При высокой интенсивности потока это может приводить к увеличению числа операций записи и индексирования, тогда как при низкой нагрузке возрастает время формирования блоков.

Исходя из нашего сравнения, можно сделать вывод, что адаптивный метод более устойчив к изменению параметров среды и обеспечивает более предсказуемое поведение системы при различных режимах нагрузки.

СЦЕНАРИИ ВНЕДРЕНИЯ АЛГОРИТМА

Предложенный алгоритм адаптивного формирования блоков и индексирования неструктурированных данных может быть применён в различных классах децентрализованных систем, где наблюдается высокая динамика потоков данных и ограниченность сетевых ресурсов. Ниже рассмотрены ключевые сценарии его внедрения.

1. Децентрализованные системы хранения данных (IPFS-подобные системы)

Сценарий внедрения:

В системах контент-адресуемого хранения, таких как IPFS и аналогичные решения, данные распределяются по узлам сети и идентифицируются с использованием хеш-функций [4]. При

обработке большого объёма неструктурированных текстовых данных возникает проблема избыточной фрагментации и увеличения количества мелких блоков.

Рекомендации по применению.

Использование предлагаемого алгоритма целесообразно в следующих случаях:
при высокой интенсивности поступления данных $\lambda(t)$;

- при увеличении количества мелких файлов и документов;
- при необходимости оптимизации распределённого индексирования.

Алгоритм позволяет:

- агрегировать данные в адаптивные блоки;
- уменьшить количество операций записи в DHT;
- повысить эффективность поиска за счёт укрупнённых индексных структур.

Потенциальные проблемы и вызовы:

- увеличение времени доступа к отдельным документам внутри блока;
- необходимость адаптации существующих механизмов chunking;
- дополнительные вычислительные затраты на адаптацию параметров.

Возможные решения:

- использование многоуровневой индексации;
- внедрение кэширования популярных данных;
- оптимизация параметров α и β под конкретную нагрузку.

2. Децентрализованные поисковые системы

Сценарий внедрения:

В распределённых системах поиска текстовых данных (например, P2P search engines) индексирование является одной из наиболее ресурсоёмких операций [8]. При этом статические методы формирования индексов приводят к увеличению задержек и неравномерной нагрузке на узлы.

Рекомендации по применению.

Алгоритм рекомендуется использовать:

- при необходимости масштабирования поисковой системы;
- при высокой вариативности запросов;
- в условиях неоднородной загрузки узлов.

Использование адаптивного формирования блоков позволяет:

- уменьшить количество индексных структур;
- снизить время поиска за счёт агрегированных индексов;
- обеспечить баланс нагрузки между узлами.

Потенциальные проблемы:

- рост размера индексных структур;
- сложность обновления индексов;
- возможное увеличение латентности при доступе к данным.

Возможные решения:

- применение инкрементального индексирования;
- использование распределённых кэшей;
- оптимизация структуры индекса.

3. Системы потоковой обработки данных

Сценарий внедрения:

В системах потоковой обработки (stream processing), таких как распределённые аналитические платформы, данные поступают непрерывно и требуют оперативной обработки. В таких условиях фиксированные параметры буферизации могут приводить к перегрузке системы. Современные системы потоковой обработки данных, такие как описанные в [12, 13], используют динамическое управление окнами обработки, что концептуально близко к предлагаемому подходу.

Рекомендации по применению.

Алгоритм эффективен:

- при переменной интенсивности потоков данных;
- в системах реального времени;
- при ограниченных сетевых ресурсах.

Адаптивная модель позволяет:

- динамически изменять размер буфера (блока);
- предотвращать перегрузку сети;
- оптимизировать задержки обработки.

Потенциальные проблемы:

- необходимость точной оценки параметров $\lambda(t)$, $L(t)$;
- сложность интеграции с существующими streaming-фреймворками.

Возможные решения:

- использование методов мониторинга нагрузки;
- внедрение механизмов прогнозирования потока данных;
- интеграция с системами управления потоками.

РЕКОМЕНДАЦИИ ПО ИНТЕГРАЦИИ АЛГОРИТМА

Интеграция алгоритма адаптивного формирования блоков в существующие децентрализованные системы требует поэтапного подхода и учёта архитектурных особенностей конкретной платформы.

1. Условия целесообразности внедрения.

Использование алгоритма рекомендуется в следующих случаях:

- высокая интенсивность входного потока данных;
- наличие перегрузок сети (высокие значения $L(t)$);
- необходимость масштабирования системы;
- большое количество мелких данных.

2. Случаи, когда внедрение нецелесообразно

Алгоритм может быть избыточным:

- в системах с низкой нагрузкой;
- при малом объёме данных;
- в централизованных архитектурах с фиксированными ресурсами.

3. Этапы интеграции алгоритма

Этап 1: Анализ системы:

- определение текущих параметров: $\lambda(t)$, $L(t)$, $N(t)$;
- выявление узких мест;
- оценка требований к производительности.

Этап 2: Модификация архитектуры:

- внедрение модуля адаптивного формирования блоков;
- интеграция с системой индексирования;
- обеспечение совместимости с DHT.

Этап 3: Реализация мониторинга:

- сбор метрик нагрузки сети;
- оценка интенсивности потока данных;
- отслеживание производительности.

Этап 4: Настройка параметров модели:

- выбор коэффициентов α , β ;
- определение пороговых значений;
- проведение тестирования.

Этап 5: Тестирование:

- нагрузочное тестирование;
- проверка устойчивости системы;
- анализ времени отклика.

Этап 6: Развёртывание:

- поэтапное внедрение алгоритма;
- обновление узлов сети;
- контроль корректности работы.

Этап 7: Мониторинг и оптимизация:

- анализ ключевых метрик (время формирования блока, нагрузка сети, скорость поиска);
- корректировка параметров модели.

4. Практические рекомендации:

- использовать адаптивный алгоритм совместно с кэшированием;
- учитывать неоднородность узлов сети;
- применять гибкую настройку параметров;
- проводить регулярную оптимизацию модели.

ЗАКЛЮЧЕНИЕ

В работе предложен метод адаптивного формирования блоков и индексирования неструктурированных данных в децентрализованных системах хранения, учитывающий динамические характеристики распределённой среды, включая интенсивность поступления данных, загрузку сети и количество активных узлов.

Разработанная архитектура системы объединяет этапы предобработки, агрегации, индексирования и последующего размещения данных в распределённой среде. В отличие от ряда существующих решений, в основе предложенного подхода лежит динамическое определение параметров формирования блоков, включая их размер и время накопления, что позволяет учитывать текущее состояние сети и характеристики входного потока данных.

В рамках исследования предложена математическая модель, описывающая механизм адаптации указанных параметров, а также реализующий её алгоритм. Теоретический анализ показал, что алгоритм корректно функционирует при различных сценариях. При этом достигается согласование между уровнем сетевой нагрузки и эффективностью поиска.

Рассмотренные варианты применения и предложенные рекомендации по внедрению подтверждают, что метод может использоваться в различных типах децентрализованных систем – от распределённых хранилищ до поисковых платформ и систем потоковой обработки данных.

Предложенный подход может быть использован как основа для повышения эффективности обработки неструктурированных данных в распределённых средах хранения, особенно в условиях изменяющейся нагрузки и неоднородности сети.

Список литературы

1. Gandomi A., Haider M. Beyond the hype: Big data concepts, methods, and analytics // International Journal of Information Management. – 2015. – Vol. 35, No. 2. – P. 137–144.
2. Михнев И.П. Цифровые технологии Big Data в современном высшем образовании: технологии поиска и обработки неструктурированной информации // Материалы конференции. – Новосибирск, 2019. – С. 326–329.
3. Фирова Д.В., Барышникова М.Ю. Обзор методов извлечения данных из неструктурированных документов // Матрица научного познания. – 2022. – № 2-1. – С. 56–71.
4. Benet J. IPFS – Content Addressed, Versioned, P2P File System // arXiv preprint arXiv:1407.3561, 2014.
5. Maymounkov P., Mazières D. Kademlia: A Peer-to-Peer Information System Based on the XOR Metric // IPTPS. – 2002. – P. 53–65.
6. Tanenbaum A.S., van Steen M. Distributed Systems: Principles and Paradigms. – Pearson, 2007.
7. Manning C.D., Raghavan P., Schütze H. Introduction to Information Retrieval. – Cambridge University Press, 2008.

8. Xu Y., Chen L. Efficient Indexing and Query Processing in Distributed Text Retrieval Systems // IEEE Access. – 2020. – Vol. 8. – P. 112345–112357.
9. Li J., Chen X. Decentralized Storage Systems: Architecture and Challenges // IEEE Access. – 2020. – Vol. 8. – P. 227093–227105.
10. Stoica I. et al. Chord: A Scalable Peer-to-Peer Lookup Protocol // IEEE/ACM Transactions on Networking. – 2003. – Vol. 11. – P. 17–32.
11. Wang S., Li X. Dynamic Resource Allocation in Distributed Networks // IEEE Transactions on Cloud Computing. – 2022. – Vol. 10. – P. 45–58.
12. Carbone P. et al. Apache Flink: Stream and Batch Processing in a Single Engine // IEEE Data Engineering Bulletin. – 2015.
13. Akidau T. et al. The Dataflow Model: A Practical Approach to Balancing Correctness, Latency, and Cost in Massive-Scale Systems // VLDB. – 2015.
14. Kleinrock L. Queueing systems. Volume 1: Theory. – New York: Wiley, 1975. – 417 p.

References

1. Gandomi A., Haider M. Beyond the hype: Big data concepts, methods, and analytics // International Journal of Information Management. – 2015. – Vol. 35, No. 2. – P. 137–144.
2. Mikhnev I.P. Digital technologies of Big Data in modern higher education: technologies of search and processing of unstructured information // Conference proceedings. Novosibirsk, 2019. – pp. 326–329.
3. Firova D.V., Baryshnikova M.Y. Review of data extraction methods from unstructured documents // Matrix of scientific knowledge. – 2022. – No. 2-1. – pp. 56–71.
4. Benet J. IPFS – Content Addressed, Versioned, P2P File System // arXiv preprint arXiv:1407.3561, 2014.
5. Maymounkov P., Mazières D. Kademlia: A Peer-to-Peer Information System Based on the XOR Metric // IPTS. – 2002. – P. 53–65.
6. Tanenbaum A.S., van Steen M. Distributed Systems: Principles and Paradigms. – Pearson, 2007.
7. Manning C.D., Raghavan P., Schütze H. Introduction to Information Retrieval. – Cambridge University Press, 2008.
8. Xu Y., Chen L. Efficient Indexing and Query Processing in Distributed Text Retrieval Systems // IEEE Access. – 2020. – Vol. 8. – P. 112345–112357.
9. Li J., Chen X. Decentralized Storage Systems: Architecture and Challenges // IEEE Access. – 2020. – Vol. 8. – P. 227093–227105.
10. Stoica I. et al. Chord: A Scalable Peer-to-Peer Lookup Protocol // IEEE/ACM Transactions on Networking. – 2003. – Vol. 11. – P. 17–32.
11. Wang S., Li X. Dynamic Resource Allocation in Distributed Networks // IEEE Transactions on Cloud Computing. – 2022. – Vol. 10. – P. 45–58.
12. Carbone P. et al. Apache Flink: Stream and Batch Processing in a Single Engine // IEEE Data Engineering Bulletin. – 2015.
13. Akidau T. et al. The Dataflow Model: A Practical Approach to Balancing Correctness, Latency, and Cost in Massive-Scale Systems // VLDB. – 2015.
14. Kleinrock L. Queueing systems. Volume 1: Theory. – New York: Wiley, 1975. – 417 p.

Воскобойников Илья Сергеевич, соискатель по специальности 2.3.1. Системный анализ, управление и обработка информации, статистика, Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, Россия

Гвоздецкий Игорь Николаевич, кандидат технических наук, доцент, начальник управления информатизации, Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, Россия

Булгаков Владислав Дмитриевич, соискатель по специальности 2.3.1. Системный анализ, управление и обработка информации, статистика, Белгородский государственный технологический университет им. В.Г. Шухова, г. Белгород, Россия

Voskoboinikov Ilia Sergeevich, Applicant in the Specialty 2.3.1. System analysis, management and information processing, statistics, Belgorod State Technological University named after V.G. Shukhov, Belgorod, Russia

Gvozdevsky Igor Nikolaevich, Candidate of Technical Sciences, Associate Professor, Head of the Informatization Department of the Belgorod State Technological University named after V.G. Shukhov, Belgorod, Russia

Bulgakov Vladislav Dmitrievich, Applicant in the Specialty 2.3.1. System analysis, management and information processing, statistics, Belgorod State Technological University named after V.G. Shukhov, Belgorod, Russia

УДК 004.65:004.946:636.2.034

DOI: 10.18413/2518-1092-2026-11-2-0-11

Горелов С.А.¹
Клёсов Д.Н.²
Белецкая А.А.³
Афонин А.Н.³
Ядута А.З.³

КЛАССИФИКАЦИОННАЯ МОДЕЛЬ И ИНТЕРАКТИВНАЯ ВИРТУАЛЬНАЯ СРЕДА ДЛЯ СЦЕНАРНОГО АНАЛИЗА ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ ЖИВОТНОВОДСТВА

¹⁾ Федеральное государственное бюджетное образовательное учреждение высшего образования «Белгородский государственный аграрный университет имени В.Я. Горина», ул. Вавилова, 1, Белгородская область, Белгородский район, п. Майский, 308503, Россия

²⁾ Федеральное государственное бюджетное образовательное учреждение высшего образования «МИРЭА – Российский технологический университет», Проспект Вернадского, 78, г. Москва, 119454, Россия

³⁾ Белгородский государственный национальный исследовательский университет, ул. Победы, 85, г. Белгород, 308015, Россия

e-mail: d.n.klesov@yandex.ru

Аннотация

Цифровизация животноводства повышает требования к анализу регламентированных процедур, поскольку состояние процесса зависит не только от значений параметров, но и от стадии, последовательности действий и событийных нарушений. В статье предложен подход к оценке таких процессов на основе классификационной модели, связанной с интерактивной виртуальной средой. Модель объединяет стадии процесса, параметры, события нарушения регламента, нормированные отклонения и правила отнесения процесса к одному из классов состояния. Проверка выполнена на примере машинного доения на десяти тестовых сценариях, отражающих нормативные, отклоняющиеся, критические и пограничные режимы. В девяти случаях расчетный класс совпал с экспертной оценкой; расхождение возникло вблизи порога предкритического состояния, что показывает необходимость настройки весов и порогов. VR-среда рассматривается как визуально-аналитический интерфейс, отображающий стадию процесса, отклонения, события, интегральную оценку и итог сценария.

Ключевые слова: классификационная модель; виртуальная среда; технологические процессы животноводства; машинное доение; сценарный анализ; дискретно-событийное моделирование; системный анализ; поддержка принятия решений

Для цитирования: Горелов С.А., Клёсов Д.Н., Белецкая А.А., Афонин А.Н., Ядута А.З. Классификационная модель и интерактивная виртуальная среда для сценарного анализа технологических процессов животноводства // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 135-150. DOI: 10.18413/2518-1092-2026-11-2-0-11

Gorelov S.A.¹
Klyosov D.N.²
Beletskaya A.A.³
Afonin A.N.³
Yaduta A.Z.³

CLASSIFICATION MODEL AND INTERACTIVE VIRTUAL ENVIRONMENT FOR SCENARIO ANALYSIS OF TECHNOLOGICAL PROCESS IN LIVESTOCK PRODUCTION

¹⁾ Federal State Budget Educational Institution of Higher Education «Belgorod State Agrarian University named after V. Gorin»,
1 Vavilova St., Belgorod region, Belgorod district, village of Maisky, 308503, Russia

²⁾ Federal State Budget Educational Institution of Higher Education «MIREA – Russian Technological University»,
78 Vernadsky Ave., Moscow, 119454, Russia

³⁾ Belgorod State National Research University,
85 Pobedy St., Belgorod, 308015, Russia

e-mail: d.n.klesov@yandex.ru

Abstract

Digitalization of animal husbandry increases the requirements for the analysis of regulated procedures, since the state of the process depends not only on the values of the parameters, but also on the stage, sequence of actions and event violations. The article suggests an approach to evaluating such processes based on a classification model associated with an interactive virtual environment. The model combines the stages of the process, parameters, events of violation of regulations, normalized deviations, and rules for assigning a process to one of the status classes. The check was performed on an example of machine milking based on ten test scenarios reflecting regulatory, deviant, critical and borderline regimes. In nine cases, the calculated class coincided with the expert assessment; the discrepancy occurred near the threshold of the precritical state, which indicates the need to adjust the weights and thresholds. The VR environment is considered as a visual analytical interface that displays the stage of the process, deviations, events, an integrated assessment and the outcome of the scenario.

Keywords: classification model; virtual environment; livestock technological processes; machine milking; scenario analysis; discrete-event modeling; systems analysis; decision support

For citation: Gorelov S.A., Klyosov D.N., Beletskaya A.A., Afonin A.N., Yaduta A.Z. Classification Model and Interactive Virtual Environment for Scenario Analysis of Technological Process in Livestock Production // Research result. Information technologies. – T.11, №2, 2026. – P. 135-150. DOI: 10.18413/2518-1092-2026-11-2-0-11

ВВЕДЕНИЕ

Современные животноводческие комплексы являются киберфизическими системами, где оборудование, сенсоры, программные модули, процедуры и биологические объекты формируют параметрические и событийные данные для мониторинга, системного анализа и принятия решений [1-3].

Исследования охватывают мониторинг и поддержку принятия решений в животноводстве [4-6], классификацию состояний и выявление отклонений в технических и киберфизических системах [7-9], а также визуальную аналитику, VR/AR и цифровые двойники [10-11].

Однако эти направления недостаточно интегрированы применительно к регламентированным процессам животноводства. Традиционные интерфейсы отображают отдельные параметры, но не всегда связывают их со стадией процесса, источником отклонения, событием нарушения и итоговым классом состояния. VR-решения чаще используются для обучения и демонстрации, тогда как применение виртуальной среды как аналитического интерфейса классификационной модели разработано ограниченно [12-13].

В связи с этим целью работы является разработка классификационной модели оценки состояния регламентированных технологических процессов животноводства и ее интеграция с интерактивной виртуальной средой для сценарного анализа и визуального представления результатов. Научная новизна работы состоит в том, что интерактивная виртуальная среда рассматривается как аналитический интерфейс классификационной модели регламентированного технологического процесса, а не как самостоятельный демонстрационный или обучающий модуль. В качестве прикладного кейса для проверки предложенной постановки в работе используется процесс машинного доения.

ОСНОВНАЯ ЧАСТЬ

Объектом исследования являются регламентированные технологические процессы животноводческого комплекса как элементы киберфизической системы, включающей оборудование, сенсоры, программные модули, технологические зоны и биологические объекты. Модель ориентирована на процессы со стадийной структурой, нормативными диапазонами параметров и событийными нарушениями. В качестве кейса рассматривается машинное доение с

фиксированной последовательностью операций, временными ограничениями и типовыми отклонениями.

Исходные данные включают количественные параметры и события нарушения регламента, а именно временные интервалы, режимы оборудования, длительность операций, изменение порядка действий, пропуск операции, превышение времени этапа и отказ оборудования. Аprobация выполняется на тестовом наборе нормативных, отклоняющихся, комбинированных, критических и пограничных сценариев. Параметры сценариев, веса и пороги заданы экспертно для проверки логики модели и подлежат калибровке по эксплуатационным данным. Управляющие воздействия рассматриваются как сценарии типа «что-если» [14].

Для согласованного описания технологического процесса, его объектов, стадий, состояний, параметров и событийных нарушений используется классификационная модель

$$M = \langle O, P, G, S, X, E, R \rangle, \quad (1)$$

где O – множество объектов процесса; P – множество технологических процессов; G – множество стадий выполнения процесса; S – множество состояний процесса; X – множество контролируемых параметров; E – множество событийных признаков нарушения регламента; R – множество отношений между элементами модели.

Отношение R задается как объединение типизированных связей

$$R = R_{OP} \cup R_{PG} \cup R_{PS} \cup R_{PX} \cup R_{OO}, \quad (2)$$

где $R_{OP} \subseteq O \times P$ – принадлежность объекта технологическому процессу; $R_{PG} \subseteq P \times G$ – связь процесса со стадиями выполнения; $R_{PS} \subseteq P \times S$ – допустимые состояния процесса; $R_{PX} \subseteq P \times X$ – связь процесса с контролируемыми параметрами; $R_{OO} \subseteq O \times O$ – структурные и функциональные связи между объектами.

С позиций математического моделирования рассматриваемый технологический процесс описывается как гибридная дискретно-непрерывная система. Ее непрерывная часть связана с изменением контролируемых параметров во времени, а дискретная – со сменой стадий процесса и регистрацией событийных нарушений.

Вектор контролируемых параметров процесса задается выражением

$$x(t) = (x_1(t), x_2(t), \dots, x_n(t)), \quad (3)$$

где $x_i(t)$ – значение i -го контролируемого параметра в момент времени t .

Управляющие воздействия описываются вектором

$$u(t) = (u_1(t), u_2(t), \dots, u_m(t)), \quad (4)$$

где $u_j(t)$ – j -й управляющий параметр, определяющий режим функционирования оборудования, временные характеристики выполнения операций или допустимые корректирующие воздействия.

Стадийная структура процесса задается множеством

$$G = \{g_1, g_2, \dots, g_r\}, \quad (5)$$

где g_i – элементы множества, соответствующие последовательным этапам выполнения технологической процедуры. Для процесса машинного доения в дальнейшем рассматриваются стадии подготовки, подключения аппарата, выполнения доения и контроля, завершения процедуры.

Множество состояний процесса задается как

$$S = \{s_1, s_2, s_3, s_4\}, \quad (6)$$

где s_1 – нормальное состояние, s_2 – допустимое состояние, s_3 – предкритическое состояние, s_4 – критическое состояние.

В модели различаются стадии процесса и состояния процесса. Стадии g_i отражают последовательность технологических операций, тогда как состояния s_i характеризуют качество и устойчивость протекания процесса. Поэтому один и тот же параметр может иметь различную интерпретацию в зависимости от текущей стадии выполнения процедуры.

Для каждого параметра $x_i(t)$ на стадии g_i стадийной структуры G задается нормативный интервал

$$I_i(g) = [a_i(g), b_i(g)] \quad (7)$$

где $a_i(g)$ и $b_i(g)$ – нижняя и верхняя допустимые границы параметра на соответствующей стадии. Такое представление позволяет учитывать стадийно-зависимый характер нормативов и не интерпретировать параметры вне контекста текущего этапа процесса.

Событийные нарушения регламента описываются бинарным вектором

$$e(t) = (e_1(t), e_2(t), \dots, e_q(t)), \quad e_k(t) \in \{0, 1\} \quad (8)$$

где $e_k(t) = 1$ означает наличие k -го события нарушения в момент времени t .

Множество событий разделяется на два подмножества:

$$E = E^{pr} \cup E^{cr}, \quad (9)$$

где E^{pr} – множество предкритических событий, E^{cr} – множество критических событий.

Для формализации их влияния вводятся индикаторы

$$\eta_{pr}(t) = \max_{k \in K_{pr}} e_k(t), \eta_{cr}(t) = \max_{k \in K_{cr}} e_k(t), \quad (10)$$

где K_{pr} – множество индексов предкритических событий, K_{cr} – множество индексов критических событий. Тогда $\eta_{pr}(t) = 1$ означает наличие хотя бы одного предкритического события, а $\eta_{cr}(t) = 1$ – наличие хотя бы одного критического события.

Для приведения параметров различной размерности к сопоставимому виду используется нормированная оценка отклонения от нормативного интервала. Для параметра $x_i(t)$ вводится функция расстояния до допустимой области

$$\rho_i(x_i(t), I_i(g)) = \begin{cases} 0, & x_i(t) \in I_i(g), \\ a_i(g) - x_i(t), & x_i(t) < a_i(g), \\ x_i(t) - b_i(g), & x_i(t) > b_i(g), \end{cases} \quad (11)$$

после чего вычисляется нормированное отклонение

$$\delta_i(t) = \min \left\{ 1, \frac{\rho_i(x_i(t), I_i(g))}{\Delta_i(g)} \right\} \quad (12)$$

где $\Delta_i(g) > 0$ – нормирующая ширина отклонения для параметра x_i на стадии g .

Для интегрального учета параметрических и событийных признаков используется агрегированная оценка

$$D(t) = \sum_{i=1}^n w_i \delta_i(t) + \sum_{k=1}^q v_k e_k(t) \quad (13)$$

где w_i – вес значимости отклонения i -го параметра, v_k – вес значимости k -го события нарушения.

Для обеспечения интерпретируемости вводится условие нормировки

$$\sum_{i=1}^n w_i + \sum_{k=1}^q v_k = 1 \quad (14)$$

Текущее состояние процесса определяется по иерархическим исключающим правилам, в которых событийные нарушения имеют приоритет над пороговой оценкой параметрических отклонений:

$$s(t) = \begin{cases} s_4, & \eta_{cr}(t) = 1, \\ s_3, & \eta_{cr}(t) = 0 \text{ и } (\eta_{pr}(t) = 1 \text{ или } D(t) > \theta_2), \\ s_2, & \eta_{cr}(t) = 0, \eta_{pr}(t) = 0, \theta_1 < D(t) \leq \theta_2, \\ s_1, & \eta_{cr}(t) = 0, \eta_{pr}(t) = 0, D(t) \leq \theta_1. \end{cases} \quad (15)$$

где θ_1 – порог перехода от нормального состояния к допустимому, θ_2 – порог перехода от допустимого состояния к предкритическому, причем $0 \leq \theta_1 < \theta_2 \leq 1$.

В расчетных экспериментах пороговые значения приняты равными $\theta_1=0,30$ и $\theta_2=0,60$ (в дальнейшем подлежат уточнению).

Для сравнительной оценки сценариев управления используется интегральный риск

$$R(u) = \lambda_1 \bar{D}(u) + \lambda_2 \tau_{pr}(u) + \lambda_3 v_{cr}(u) \quad (16)$$

где $\bar{D}(u)$ – среднее значение интегральной оценки отклонения при реализации сценария u , $\tau_{pr}(u)$ – доля времени нахождения процесса в неблагоприятном режиме, $v_{cr}(u)$ – нормированное число критических событий, $\lambda_1, \lambda_2, \lambda_3$ – коэффициенты значимости, удовлетворяющие условию

$$\lambda_1 + \lambda_2 + \lambda_3 = 1 \quad (17)$$

причем $\lambda_1, \lambda_2, \lambda_3 \geq 0$.

Итоговая оценка сценария определяется целевой функцией

$$J(u) = \alpha R(u) + \beta C(u) \quad (18)$$

где $C(u)$ – нормированная оценка затрат на реализацию сценария, α и β – коэффициенты значимости риска и затрат, $\alpha + \beta = 1$.

Предпочтительный сценарий определяется как

$$u^* = \arg \min_{u \in U} J(u), \quad (19)$$

Поскольку множество U является конечным множеством сценариев типа «что-если», выбор предпочтительного сценария может выполняться путем полного перебора альтернатив и их последующего ранжирования.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

На основе предложенного математического аппарата сформирована прикладная модель оценки состояния процесса машинного доения. Ее структура представлена на рис. 1 и включает стадии процедуры, контролируемые параметры, событийные признаки нарушения регламента, модуль расчета интегральной оценки и блок сценарной оценки управляющих воздействий.




Рис. 1. Структура модели процесса машинного доения

Fig. 1. Structure of the machine milking process model

Система признаков приведена в табл. 1. Нормативные диапазоны заданы с учетом регламентной логики процесса и требований к доильному оборудованию [15-17]. Веса признаков рассматриваются как экспертные значения, подлежащие дальнейшей калибровке.

Таблица 1

Система признаков для расчета состояния процесса машинного доения

Table 1

Feature set for calculating the machine milking process state

Обозначение признака	Наименование признака	Тип признака	Стадия учета	Нормативный диапазон / условие срабатывания	Весовой коэффициент
x_1	Интервал между подготовкой вымени и подключением аппарата, с	Параметрический	g_1-g_2	60–120 с	0,14
x_2	Время подключения доильного аппарата, с	Параметрический	g_2	5–20 с	0,08
x_3	Уровень вакуума, кПа	Параметрический	g_2	44–48 кПа	0,16
x_4	Частота пульсации, цикл/мин	Параметрический	g_2	55–65 цикл/мин	0,10
x_5	Общая длительность доения, мин	Параметрический	g_2-g_3	4–8 мин	0,12
x_6	Остаточный поток молока перед завершением процедуры, кг/мин	Параметрический	g_3	$\leq 0,20$ кг/мин	0,08
e_1	Нарушение последовательности операций	Событийный, предкритический	g_1-g_4	1 при нарушении регламента действий	0,10
e_2	Пропуск контрольной операции	Событийный, предкритический	g_3-g_4	1 при отсутствии обязательной проверки	0,06
e_3	Потеря вакуума	Событийный, критический	g_2	1 при отказе вакуумного контура	0,10
e_4	Аварийный останов установки	Событийный, критический	g_2	1 при аварийном завершении процедуры	0,06

Алгоритм вычислительной идентификации состояния процесса приведен на рис. 2. Он включает определение текущей стадии, выбор нормативных интервалов, расчет нормированных

отклонений параметров, учет событийных нарушений, вычисление интегральной оценки и отнесение процесса к одному из классов состояния.

Результаты алгоритма используются также для отображения в интерактивной виртуальной среде. Передаются текущая стадия процедуры, значение $D(t)$, признаки событийных нарушений и итоговый класс состояния.




Рис. 2. Алгоритм вычислительной идентификации состояния процесса

Fig. 2. Algorithm for computational identification of the process state

Для проверки модели сформирован тестовый набор из десяти сценариев машинного доения (табл. 2), включающий нормативные, отклоняющиеся, комбинированные, критические и пограничные режимы. Эталонные классы заданы экспертно и используются для сопоставления с расчетной классификацией.

Таблица 2

Сценарии тестовой оценки классификационной модели процесса машинного доения

Table 2

Test scenarios for evaluating the classification model of the machine milking process

№ сценария	Наименование сценария	Стадия процесса	Тип отклонения	Изменяемые параметры / события	Ожидаемый класс состояния
S1	Нормативное выполнение процедуры	g1-g4	Нет отклонения	Параметры в норме, событий нет	S1
S2	Незначительная задержка подключения аппарата	g1-g2	Параметрическое, слабое	Рост интервала подключения	S1
S3	Увеличение интервала подключения аппарата	g1-g2	Параметрическое	Превышение интервала подключения	S2
S4	Нестабильность вакуума	g2	Параметрическое	Отклонение уровня вакуума и частоты пульсации	S2
S5	Пограничная длительность доения	g2-g3	Пограничное параметрическое	Длительность у верхней границы	S3
S6	Превышение длительности доения	g2-g3	Параметрическое, выраженное	Значительное превышение длительности доения, отклонение завершающих параметров	S3
S7	Нарушение порядка действий	g3-g4	Событийное, предкритическое	Пропуск контроля / нарушение порядка	S3
S8	Потеря вакуума	g2	Событийное, критическое	Отказ вакуумного контура	S4
S9	Комбинированное нарушение режима	g1-g3	Комбинированное	Задержка подключения + нестабильность вакуума + пропуск контроля	S3
S10	Аварийный останов	g2	Комбинированное, критическое	Останов установки и прерывание процедуры	S4

Сценарии S1-S10 охватывают нормативные, параметрические, событийные, критические, комбинированные и пограничные режимы, включая ситуацию S9 с одновременным влиянием временного отклонения, нестабильности оборудования и пропуска контроля.

Результаты расчетной классификации приведены в табл. 3, а распределение интегральной оценки по сценариям - на рис. 3. Совпадение расчетного и экспертного классов получено в 9 из 10 случаев, что соответствует доле совпадений 0,90.

Таблица 3

Результаты классификации тестовых сценариев

Table 3

Classification results for test scenarios

№ сценария	Значение интегральной оценки (D)	Наличие предкритических событий	Наличие критических событий	Расчетный класс состояния	Эталонный класс состояния	Совпадение / расхождение
S1	0,08	0	0	S1	S1	Совпадение
S2	0,27	0	0	S1	S1	Совпадение
S3	0,34	0	0	S2	S2	Совпадение
S4	0,46	0	0	S2	S2	Совпадение
S5	0,59	0	0	S2	S3	Расхождение
S6	0,67	0	0	S3	S3	Совпадение
S7	0,24	1	0	S3	S3	Совпадение
S8	0,21	0	1	S4	S4	Совпадение
S9	0,53	1	0	S3	S3	Совпадение
S10	0,71	0	1	S4	S4	Совпадение




Рис. 3. Изменение интегральной оценки состояния по сценариям процесса машинного доения
Fig. 3. Change in the integral state score across machine milking scenarios

Сценарии S6 и S9 отнесены к предкритическим из-за выраженных отклонений, S7 - из-за событийного нарушения при низком D, а S8 и S10 - к критическим вследствие критических событий. Расхождение выявлено только для S5. При $D = 0,59$ модель относит его к s_2 , экспертная оценка - к s_3 , что требует калибровки порогов и весов.

VR-среда на рис. 4 отображает действия, подсказки, параметры, события, $D(t)$, класс состояния и итоговый отчет, выступая визуально-аналитическим интерфейсом модели.




Рис. 4. Функциональная композиция интерфейса интерактивной VR-среды для анализа процесса машинного доения: а – выполнение технологической операции; б – сценарная подсказка и контроль действия; в – аналитическая панель состояния процесса; г – итоговый отчет по сценарию

Fig. 4. Functional composition of the interactive VR environment interface for machine milking process analysis: a – execution of a technological operation; b – scenario prompt and action control; c – analytical dashboard of the process state; d – final scenario report

Для демонстрации сценарного анализа сформировано множество управленческих воздействий $U = \{U_0, U_1, U_2, U_3, U_4\}$, отражающих возможные корректирующие действия для проблемной ситуации S9. Значения средней интегральной оценки, доли времени в предкритическом состоянии и нормированной оценки критических событий рассматриваются как расчетные показатели сценариев типа «что-если» и подлежат дальнейшему уточнению по эксплуатационным данным. Результаты ранжирования приведены в табл. 4; при расчете использованы коэффициенты $\lambda_1 = 0,5$, $\lambda_2 = 0,3$, $\lambda_3 = 0,2$, $\alpha = 0,7$, $\beta = 0,3$.

Таблица 4

Ранжирование сценариев управления по интегральному риску и затратам

Table 4

Ranking of management scenarios by integral risk and cost

№ сценария управления	Краткое описание воздействия	Средняя интегральная оценка отклонения $\bar{D}(u)$	Доля времени в предкритическом состоянии $\tau_{pr}(u)$	Нормированное число критических событий $\nu_{cr}(u)$	Интегральный риск $R(u)$	Оценка затрат $C(u)$	Целевая функция $J(u)$	Ранг сценария
U ₀	Без воздействия	0,62	0,60	0,20	0,53	0,00	0,371	5
U ₁	Сокращение интервала подключения	0,48	0,40	0,10	0,38	0,20	0,326	4
U ₂	Стабилизация вакуума	0,41	0,30	0,10	0,315	0,28	0,305	3
U ₃	Дополнительный контроль	0,37	0,22	0,05	0,261	0,18	0,237	2
U ₄	Интервал + вакуум + контроль	0,19	0,05	0,00	0,110	0,42	0,203	1

Наибольшее значение целевой функции получено для U₀, соответствующего отсутствию корректирующего воздействия. Частичные меры U₁-U₃ последовательно снижают интегральный риск и J(u). Минимальное значение целевой функции имеет комплексный сценарий U₄, сочетающий коррекцию временного интервала, стабилизацию вакуумного режима и дополнительный контроль. Сценарий U₃ может рассматриваться как компромиссный вариант, поскольку обеспечивает снижение риска при меньшей оценке затрат. Следовательно, модель пригодна не только для классификации состояния, но и для сравнительной оценки управленческих воздействий.

ЗАКЛЮЧЕНИЕ

В работе предложен подход к классификационному моделированию регламентированных процессов животноводства на основе стадийного, параметрического и событийного описания. В качестве кейса рассмотрено машинное доение. Модель включает нормированные отклонения, интегральную оценку и иерархические правила классификации четырех состояний.

Апробация на десяти сценариях дала совпадение расчетного и экспертного классов в 9 из 10 случаев. Расхождение для S5 при D = 0,59 показало необходимость калибровки весов и порога $\theta_2 = 0,60$. Ранжирование воздействий для S9 выявило минимальное значение целевой функции для U₄, а U₃ может рассматриваться как компромисс при ограниченных затратах.

Практическая значимость связана с VR-средой, отображающей стадию, параметры, события, интегральную оценку и класс состояния. Дальнейшая работа предполагает калибровку по эксплуатационным данным и проверку подхода на других процессах животноводства.

Список литературы

1. Айндинов Р.Р., Садыков М.Р., Зиннатуллина А.Н. Автоматизация управления технологическими процессами на базе цифровых двойников // Повышение эффективности эксплуатации мобильных машин: Научные труды Всероссийской научно-практической конференции преподавателей, студентов, аспирантов и молодых ученых, посвященной 80-летию Победы в Великой отечественной войне. Казань: Казанский ГАУ, 2025. – С. 369-378.
2. Скворцова Е.Г., Скворцов Е.А. Доля работников животноводства, взаимодействующих с технологиями искусственного интеллекта и киберфизическими системами // Проблемы взаимодействия публичного и частного права при регулировании цифровизации экономических отношений: Материалы V Международной научно-практической конференции. Екатеринбург: Уральский государственный экономический университет, 2022. – С. 123-126.
3. Цифровизация агропромышленного комплекса / П.П. Гамаюнов, Ю.А. Славина, С.А. Алексеев, Куверин И.Ю., Кобиашвили Е.И. // Научная жизнь. – 2023. – Т. 18, № 6(132). – С. 878-887. – DOI 10.26088/1991-9476-2023-18-6-878-887.
4. Сапрыкин И.А., Гусева Ю.Д. Перспективные направления применения цифровых технологий в агропромышленном комплексе // Цифровизация агропромышленного комплекса: Сборник научных статей III Международной научно-практической конференции. Тамбов: Издательский центр ФГБОУ ВО Тамбовский государственный технический университет, 2022. – С. 487-490.
5. Коробской Р.А., Савинская Д.Н. Система поддержки принятия решений для отрасли животноводства // Цифровизация экономики: направления, методы, инструменты: Сборник материалов II всероссийской научно-практической конференции. Краснодар: Кубанский ГАУ имени И.Т. Трубилина, 2020. – С. 391-393.
6. Гринченков Д.В., Романенко И.В., Профатило В.К. Цифровые технологии в системах поддержки принятия решений для животноводства // Инженерный вестник Дона. – 2025. – № 6(126). – С. 627-643.
7. Патент № 2800740 С1 Российская Федерация, МПК G06F 21/00. Система и способ выявления аномалий в киберфизической системе: № 2022123995: заявл. 09.09.2022: опубл. 27.07.2023 / А. Б. Лаврентьев, А.М. Воронцов, А.М. Нечипорук [и др.]; заявитель Акционерное общество "Лаборатория Касперского".
8. Горелова Г.В. Киберфизические системы и когнитивное моделирование сложных систем // Проблемы управления безопасностью сложных систем: Материалы XXVII международной конференции. Москва: Институт проблем управления им. В.А. Трапезникова РАН, 2019. – С. 299-304. – DOI: 10.25728/pubss.2019.299.
9. Вторый В.Ф., Вторый С.В. метод диагностики доильных установок с использованием цифровых технологий // Таврический вестник аграрной науки. – 2020. – № 4(24). – С. 20-28. – DOI 10.33952/2542-0720-2020-4-24-20-28.
10. Кудряшов К.С. Использование цифровых двойников для прогнозирования сбоев и повышения живучести автоматизированных систем // Цифровая экономика и безопасность: вызовы и перспективы: Сборник научных трудов по итогам II Всероссийской студенческой научно-практической конференции. Москва: МИРЭА - Российский технологический университет, 2025. – С. 99-102.
11. Кудрявцева А.С. Киберфизическая система как развитие автоматизации на всех этапах жизненного цикла деятельности предприятия на основе внедрения цифровых // Системный анализ в проектировании и управлении: Сборник научных трудов XXIII Международной научно-практической конференции. Санкт-Петербург: ФГАОУ ВО Санкт-Петербургский политехнический университет Петра Великого, 2019. – С. 312-320.
12. Семантическая интерпретация эффекта погружения в виртуальную реальность / И.А. Розанов, К.А. Грунчева, В.Ю. Ратникова, А.М. Житенёва // Экспериментальная психология в социальных практиках: Материалы 4-ой международной научно-практической конференции. Москва: Универсум, 2024. – С. 153-169.
13. Свидетельство о государственной регистрации программы для ЭВМ № 2021667437 Российская Федерация. Модуль анализа поведения человека в среде виртуальной и дополненной реальности: № 2021665218: заявл. 29.09.2021: опубл. 29.10.2021 / С.С. Чаплыгин, С.В. Ровнов, Е.О. Монин [и др.]; заявитель ФГБОУ ВО Самарский государственный медицинский университет Министерства здравоохранения Российской Федерации.
14. Decision support for choosing VR technologies / Klyosov D., Gorelov S., Voinash S., Zagidullin R., Litvina P. // Conference: Proceedings of the IV International Conference on Advances in Science, Engineering and

Digital Education: ASedu-IV 2024. AIP Conference Proceedings, 3268 (1), art. no. 070014. – DOI: 10.1063/5.0257303.

15. Загороднев Ю.П. Основы технологии машинного доения коров: учебное пособие для вузов. Санкт-Петербург: Лань, 2024. – 120 с.

16. Андрианов Е.А., Бугаков Е.Е. Современные технологии машинного доения // Ветеринарно-санитарные аспекты качества и безопасности сельскохозяйственной продукции: Материалы IX международной научно-практической конференции, посвященной 90-летию со дня рождения профессора, доктора ветеринарных наук Н.М. Алтухова. Воронеж: Воронежский государственный аграрный университет им. Императора Петра I, 2025. – С. 291-294.

17. Панин А.А. Обеспечение эффективного машинного доения коров // Совершенствование инженерно-технического обеспечения производственных процессов и технологических систем: Материалы национальной научно-практической конференции с международным участием, посвященной 75-летию основания инженерного факультета ФГБОУ ВО Оренбургский ГАУ. Оренбург: Оренбургский ГАУ, 2025. – С. 385-387.

18. Influence of dairy farms' characteristics and technological level on attitude towards augmented reality / Pinna D., Sara G., Cresci R., Petronella A., Todde G., Atzori A.S., Caria M. // Sci Rep. 2026. – 16(1). – 7437. – DOI: 10.1038/s41598-026-38898-6.

19. Patrick B., Kanjo E., Kaiwartya O. Review of movement sensor applications in livestock animal activity recognition: Communications, data collection practices, and edge-AI solutions // Smart Agricultural Technology, 2026. 14. – Art. no. 101986. – DOI: 10.1016/j.atech.2026.101986.

20. IoT based tracking cattle health monitoring system using wireless sensors / Rajendran J.G., Alagarsamy M., Seva V., Dinesh P.M., Rajangam B., Suriyan K. // Bulletin of Electrical Engineering and Informatics, 12 (5), 2026. – pp. 3086-3094. – DOI: 10.11591/eei.v12i5.4610.

21. Smart Monitoring of Livestock Health and Behavior with Sensor-based Deep Learning Optimized System / Pokkuluri K.S., Bhardwaj R., Sunil M.P., Kadam K., Mishra A., Patel G.M. // Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications, 2026, 16(3). – pp. 219-240. – DOI: 10.58346/JOWUA.2025.I3.013.

22. Precision Livestock Farming and Cattle Health Management / Singh D., Singh R., Gehlot A., Pandey P.S., Yamsani N. // Lecture Notes in Networks and Systems, 1506 LNNS, 2026. – pp. 323-333. – DOI: 10.1007/978-981-96-8694-0_24.

23. Nassar N. Applications of Digital Twins in Agriculture. Digital Twin Technology for Sustainable // Agriculture: Applications, Implementation and Future Trends, 2026. – pp. 135-154. – DOI: 10.1007/978-981-95-5915-2_8.

24. Pinto A., Donoso Y., Gutierrez J.A. Balancing the trilemma: a survey of federated anomaly detection for secure cyber-physical systems // Cybersecurity, 2026. – 9 (1). – art. no. 135. – DOI: 10.1186/s42400-026-00567-6.

25. Cyber-physical anomaly detection a deep adversarial fusion of sensor and network data / Pinto A., Herrera L.-C., Donoso Y., Gutierrez J.A. // Discover Computing, 2026. – 29(1). – art. no. 183. DOI: 10.1007/s10791-026-10064-6.

26. An Immersive AI-Driven Virtual Reality Training for Accessible Agricultural Education in a Unity-Based VR Environment / Pendem A., Jawahar B., Challa K., AlHmoud I.W., Gokaraju B., Liang C.L. // Lecture Notes in Computer Science, 16446 LNCS, 2026. – pp. 77 - 91. – DOI: 10.1007/978-3-032-18474-0_6.

27. Digital Twins, Extended Reality, and Artificial Intelligence in Agriculture: Emerging Trends and Insights / Lokhande P., Mali S., Jadhav N., Khan M., Ayasrah F.T., Cengiz K. // The Convergence of Extended Reality and Metaverse in Agriculture, 2025. – pp. 77-100. – DOI: 10.4018/979-8-3373-2797-6.ch004.

28. Data-Driven Decision Making and Virtual Farming in the Agricultural Metaverse / Palanivel N., Balaji V.S., Priya V.R., Murugan M.S., Senthil K.M., Alagarsamy M. // The Convergence of Extended Reality and Metaverse in Agriculture, 2025. – pp. 161-185. – DOI: 10.4018/979-8-3373-2797-6.ch007.

29. Niu Y., Chai S.S. Design and optimization of a test case generation algorithm for real-time embedded systems based on adaptive Q-Learning // Automated Software Engineering, 2026. – 33(2). – art. no. 50. – DOI: 10.1007/s10515-026-00598-w.

30. Yang T., Choi I., Luo H. Interacting and reflecting together in VR-mediated group learning: Immersive and observational experiences in shared mixed reality // Computers and Education, 2026. – 251. – art. no. 105644. – DOI: 10.1016/j.compedu.2026.105644.

References

1. Aindinov R.R., Sadykov M.R., Zinnatullina A.N. Automation of Technological Process Management Based on Digital Twins // Improving the Efficiency of Mobile Machine Operation: Proceedings of the All-Russian Scientific and Practical Conference of Teachers, Students, Postgraduate Students, and Young Scientists Dedicated to the 80th Anniversary of Victory in the Great Patriotic War. Kazan: Kazan State Agrarian University, 2025. – Pp. 369-378.
2. Skvortsova E.G., Skvortsov E.A. The Share of Livestock Workers Engaging with Artificial Intelligence Technologies and Cyber-Physical Systems // Problems of Interaction between Public and Private Law in Regulating the Digitalization of Economic Relations: Proceedings of the V International Scientific and Practical Conference. Yekaterinburg: Ural State University of Economics, 2022. – Pp. 123-126.
3. Gamayunov P.P., Slavina Yu.A., Alekseyev S.A., Kuverin I.Yu., Kobiashvili E.I. Digitalization of the Agro-Industrial Complex // Scientific Life. – 2023. – Vol. 18, No. 6(132). – Pp. 878-887. – DOI 10.26088/1991-9476-2023-18-6-878-887.
4. Saprykin I.A., Guseva Yu.D. Promising Directions for the Application of Digital Technologies in the Agro-Industrial Complex // Digitalization of the Agro-Industrial Complex: Collection of Scientific Articles from the III International Scientific and Practical Conference. Tambov: Publishing Center of the Tambov State Technical University, 2022. – Pp. 487-490.
5. Korobskoy R.A., Savinskaya D.N. Decision Support System for the Livestock Industry // Digitalization of the Economy: Directions, Methods, and Tools: Collection of Materials from the II All-Russian Scientific and Practical Conference. Krasnodar: Kuban State Agrarian University named after I.T. Trubilin, 2020. – Pp. 391-393.
6. Grinchenkov D.V., Romanenko I.V., Profatilo V.K. Digital Technologies in Decision Support Systems for Animal Husbandry // Engineering Bulletin of the Don. – 2025. – No. 6(126). – Pp. 627-643.
7. Patent No. 2800740 C1 Russian Federation, IPC G06F 21/00. System and method for detecting anomalies in a cyber-physical system: No. 2022123995: filed on 09.09.2022: published on 27.07.2023 / A.B. Lavrentiev, A.M. Vorontsov, A.M. Nechiporuk [et al.]; applicant: Kaspersky Lab Joint-Stock Company.
8. Gorelova G.V. Cyber-Physical Systems and Cognitive Modeling of Complex Systems // Problems of Safety Management of Complex Systems: Proceedings of the XXVII International Conference. Moscow: V.A. Trapeznikov Institute of Control Sciences of the Russian Academy of Sciences, 2019. – Pp. 299-304. – DOI: 10.25728/pubss.2019.299.
9. Vtoroy V.F., Vtoroy S.V. Method for Diagnosing Milking Machines Using Digital Technologies // Tavrichesky Bulletin of Agrarian Science. – 2020. – No. 4(24). – Pp. 20-28. – DOI 10.33952/2542-0720-2020-4-24-20-28.
10. Kudryashov K.S. Using Digital Twins to Predict Failures and Improve the Survivability of Automated Systems // Digital Economy and Security: Challenges and Prospects: Collection of Scientific Papers Based on the Results of the II All-Russian Student Scientific and Practical Conference. Moscow: MIREA - Russian Technological University, 2025. – P. 99-102.
11. Kudryavtseva A.S. Cyber-physical system as the development of automation at all stages of the enterprise's life cycle based on the introduction of digital technologies // System Analysis in Design and Management: Collection of Scientific Papers of the XXIII International Scientific and Practical Conference. St. Petersburg: FGAOU VO St. Petersburg Polytechnic University of Peter the Great, 2019. – P. 312-320.
12. Semantic interpretation of the effect of immersion in virtual reality / I.A. Rozanov, K.A. Gruncheva, V.Yu. Ratnikova, A.M. Zhitenyova // Experimental Psychology in Social Practices: Materials of the 4th International Scientific and Practical Conference. Moscow: Universum, 2024. – P. 153-169.
13. Certificate of State Registration of the Computer Program No. 2021667437, Russian Federation. Module for analyzing human behavior in virtual and augmented reality environments: No. 2021665218: applied on September 29, 2021: published on October 29, 2021 / S.S. Chaplygin, S.V. Rovnov, E.O. Monin [et al.]; applicant: Samara State Medical University of the Ministry of Health of the Russian Federation.
14. Decision support for choosing VR technologies / Klyosov D., Gorelov S., Voinash S., Zagidullin R., Litvina P. // Conference: Proceedings of the IV International Conference on Advances in Science, Engineering and Digital Education: ASedu-IV 2024. AIP Conference Proceedings, 3268 (1), art. no. 070014. – DOI: 10.1063/5.0257303.
15. Zagorodnev Yu.P. Fundamentals of Machine Milking Technology for Cows: A Textbook for Universities. St. Petersburg: Lan, 2024. – 120 p.
16. Andrianov E.A., Bugakov E.E. Modern Technologies of Machine Milking // Veterinary and Sanitary Aspects of the Quality and Safety of Agricultural Products: Proceedings of the IX International Scientific and

Practical Conference Dedicated to the 90th Anniversary of Professor N.M. Altukhov, Doctor of Veterinary Sciences. Voronezh: Emperor Peter the Great Voronezh State Agrarian University, 2025. – Pp. 291-294.

17. Panin A.A. Ensuring Efficient Machine Milking of Cows // Improving Engineering and Technical Support for Production Processes and Technological Systems: Proceedings of the National Scientific and Practical Conference with International Participation Dedicated to the 75th Anniversary of the Engineering Department of the Orenburg State Agrarian University. Orenburg: Orenburg State Agrarian University, 2025. – Pp. 385-387.

18. Influence of dairy farms' characteristics and technological level on attitude towards augmented reality / Pinna D., Sara G., Cresci R., Petronella A., Todde G., Atzori A.S., Caria M. // Sci Rep. 2026. – 16(1). – 7437. – DOI: 10.1038/s41598-026-38898-6.

19. Patrick B., Kanjo E., Kaiwartya O. Review of movement sensor applications in livestock animal activity recognition: Communications, data collection practices, and edge-AI solutions // Smart Agricultural Technology, 2026. 14. – Art. no. 101986. – DOI: 10.1016/j.atech.2026.101986.

20. IoT based tracking cattle healthmonitoring system using wireless sensors / Rajendran J.G., Alagarsamy M., Seva V., Dinesh P.M., Rajangam B., Suriyan K. // Bulletin of Electrical Engineering and Informatics, 12 (5), 2026. – pp. 3086-3094. – DOI: 10.11591/eei.v12i5.4610.

21. Smart Monitoring of Livestock Health and Behavior with Sensor-based Deep Learning Optimized System / Pokkuluri K.S., Bhardwaj R., Sunil M.P., Kadam K., Mishra A., Patel G.M. // Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications, 2026, 16(3). – pp. 219-240. – DOI: 10.58346/JOWUA.2025.I3.013.

22. Precision Livestock Farming and Cattle Health Management / Singh D., Singh R., Gehlot A., Pandey P.S., Yamsani N. // Lecture Notes in Networks and Systems, 1506 LNNS, 2026. – pp. 323-333. – DOI: 10.1007/978-981-96-8694-0_24.

23. Nassar N. Applications of Digital Twins in Agriculture. Digital Twin Technology for Sustainable // Agriculture: Applications, Implementation and Future Trends, 2026. – pp. 135-154. – DOI: 10.1007/978-981-95-5915-2_8.

24. Pinto A., Donoso Y., Gutierrez J.A. Balancing the trilemma: a survey of federated anomaly detection for secure cyber-physical systems // Cybersecurity, 2026. – 9 (1). – art. no. 135. – DOI: 10.1186/s42400-026-00567-6.

25. Cyber-physical anomaly detection a deep adversarial fusion of sensor and network data / Pinto A., Herrera L.-C., Donoso Y., Gutierrez J.A. // Discover Computing, 2026. – 29(1). – art. no. 183. DOI: 10.1007/s10791-026-10064-6.

26. An Immersive AI-Driven Virtual Reality Training for Accessible Agricultural Education in a Unity-Based VR Environment / Pendem A., Jawahar B., Challa K., AlHmoud I.W., Gokaraju B., Liang C.L. // Lecture Notes in Computer Science, 16446 LNCS, 2026. – pp. 77 - 91. – DOI: 10.1007/978-3-032-18474-0_6.

27. Digital Twins, Extended Reality, and Artificial Intelligence in Agriculture: Emerging Trends and Insights / Lokhande P., Mali S., Jadhav N., Khan M., Ayasrah F.T., Cengiz K. // The Convergence of Extended Reality and Metaverse in Agriculture, 2025. – pp. 77-100. – DOI: 10.4018/979-8-3373-2797-6.ch004.

28. Data-Driven Decision Making and Virtual Farming in the Agricultural Metaverse / Palanivel N., Balaji V.S., Priya V.R., Murugan M.S., Senthil K.M., Alagarsamy M. // The Convergence of Extended Reality and Metaverse in Agric. ulture, 2025. – pp. 161-185. – DOI: 10.4018/979-8-3373-2797-6.ch007.

29. Niu Y., Chai S.S. Design and optimization of a test case generation algorithm for real-time embedded systems based on adaptive Q-Learning // Automated Software Engineering, 2026. – 33(2). – art. no. 50. – DOI: 10.1007/s10515-026-00598-w.

30. Yang T., Choi I., Luo H. Interacting and reflecting together in VR-mediated group learning: Immersive and observational experiences in shared mixed reality // Computers and Education, 2026. – 251. – art. no. 105644. – DOI: 10.1016/j.compedu.2026.105644.

Горелов Сергей Александрович, аспирант, Федеральное государственное бюджетное образовательное учреждение высшего образования «Белгородский государственный аграрный университет имени В.Я. Горина», Белгородская область, Белгородский район, п. Майский, Россия

Клёсов Дмитрий Николаевич, кандидат технических наук, доцент кафедры индустриального программирования, Федеральное государственное бюджетное образовательное учреждение высшего образования «МИРЭА – Российский технологический университет», г. Москва, Россия

Белецкая Анастасия Анатольевна, старший преподаватель кафедры трудового и предпринимательского права Юридического института, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Афонин Андрей Николаевич, доктор технических наук, профессор кафедры информационных и робототехнических систем, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Ядута Анна Зауровна, кандидат технических наук, доцент кафедры прикладной математики и компьютерного моделирования, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Gorelov Sergey Alexandrovich, Postgraduate Student, Federal State Budget Educational Institution of Higher Education «Belgorod State Agrarian University named after V. Gorin», Belgorod region, Belgorod district, village of Maisky, Russia

Klyosov Dmitry Nikolaevich, Candidate of Technical Sciences, Associate Professor of the Department of Industrial Programming, Federal State Budget Educational Institution of Higher Education «MIREA – Russian Technological University», Moscow, Russia

Beletskaya Anastasia Anatolyevna, Senior Lecturer of the Department of Labor and Entrepreneurial Law, Law Institute, Belgorod State National Research University, Belgorod, Russia

Afonin Andrey Nikolaevich, Doctor of Technical Sciences, Professor of the Department of Information and Robotic Systems, Belgorod State National Research University, Belgorod, Russia

Yaduta Anna Zaurovna, Candidate of Technical Sciences, Associate Professor of the Department of Applied Mathematics and Computer Modeling, Belgorod State National Research University, Belgorod, Russia