

Нейроинформатика, её приложения и анализ данных

XXXIII Всероссийский семинар

**Красноярск
2025**

Министерство науки и высшего образования РФ
Сибирское отделение РАН
Российская ассоциация нейроинформатики
Институт вычислительного моделирования СО РАН

НЕЙРОИНФОРМАТИКА, ЕЁ ПРИЛОЖЕНИЯ И АНАЛИЗ ДАННЫХ

МАТЕРИАЛЫ
ТРИДЦАТЬ ТРЕТЬЕГО ВСЕРОССИЙСКОГО СЕМИНАРА
26 сентября 2025 года

Красноярск 2025

УДК 007.52 (042.3)

Н 43

Нейроинформатика, её приложения и анализ данных: Материалы XXXIII Всероссийского семинара, 26 сентября 2025 года / Под ред. О.Э. Якубайлика, отв. за вып. М.Ю. Сенашова; – Красноярск: Институт вычислительного моделирования СО РАН, 2025. – 172 с.

В сборнике представлены материалы XXXIII Всероссийского семинара «Нейроинформатика, её приложения и анализ данных», проходившей в городе Красноярске 26 сентября 2025 года.

Основной задачей конференции является всесторонний и высоко квалифицированный обмен новейшими достижениями в различных областях нейроинформатики (как теории нейросетей, так и в области различных практических приложений), а также в области нелинейного статистического анализа многомерных данных, обладающих нетривиальными структурами.

Большое внимание уделено анализу областей применимости и точности методов обработки многомерных данных, анализу устойчивости различных новых (нелинейных) методов кластеризации, разбор большого числа конкретных случаев, иллюстрирующих эти проблемы и достижения.

Материалы предназначены для научных работников, преподавателей, студентов и аспирантов соответствующих специальностей.

Конференция проводится при поддержке Красноярского математического центра, финансируемого Минобрнауки РФ в рамках мероприятий по созданию и развитию региональных НОМЦ (Соглашение № 075-02-2025-1606).

Редакционная коллегия:

Якубайлик Олег Эдуардович – ответственный редактор

Сенашова Мария Юрьевна – ответственный за выпуск

© ИВМ СО РАН, 2025

© Коллектив авторов, 2025

ISBN 978-5-6054684-1-7



9 785605 468417 >

ФРАКТАЛЬНЫЕ ПАРАМЕТРЫ ИЗМЕНЕНИЯ ПСИХОФИЗИОЛОГИЧЕСКИХ ПОКАЗАТЕЛЕЙ В РЕЗУЛЬТАТЕ САМОРЕГУЛЯЦИИ

Н.М. Богатов, А.Н. Богатова, А.Л. Еремин, С.А. Сухих

Кубанский государственный университет, *bogatov@phys.kubsu.ru*

Исследование информационных процессов в мозге – одно из современных направлений психофизиологии. Для исследования нейрофизических сигналов головного мозга в психофизиологии применяются функциональная магнитно-резонансная томография (фМРТ) [1, 2], электроэнцефалография (ЭЭГ) [3, 4] и другие методы.

Регуляция физиологических процессов, направленная на поддержание жизнедеятельности организма, реализуется посредством энергетического метаболизма, использующего функциональные взаимосвязи подсистем организма. Регуляция требует особой архитектуры функциональных взаимосвязей, сформировавшейся в результате эволюции и характерной для каждого субъекта [5, 6]. Проблемы регуляции на системном уровне и передачи сигналов рассмотрены в работе [7].

Сигналы, вызванные активностью нейронов мозга, обусловленные притоком обогащённой кислородом крови, визуализируются с помощью функциональной магнитно-резонансной томографии (фМРТ). Метод применяется для определения когнитивных расстройств и диагностики нейродегенеративных заболеваний [8]. В [9] построена структурно-функциональная физическая модель расположения умственных функций в трехмерном пространстве головного мозга человека на основе данных фМРТ. В [10] исследована корреляция между результатами в эмоциональном психологическом тесте и количеством активированных пикселей в связанных с эмоциями областях мозга, измеренным с помощью фМРТ.

Использование парадигмы фМРТ и ЭЭГ в психофизических исследованиях позволяет количественно оценить активацию мозга при психоэмоциональных нагрузках и изучить процессы саморегуляции функциональных состояний [2].

Любой набор физиологических параметров человека статистически уникален. Мозговая деятельность носит двойственный характер. Она включает нейрофизиологические процессы и субъективные состояния. Происхождение субъективной мозговой активности невозможно объяснить только на основы нейрофизиологических исследований [11].

Иерархия структурных форм и размеры уровней организации интеллектуальных систем мозга и человечества имеют фрактальную структуру [12]. Специфическое влияние фрактальных изображений на психофизиологический статус человека исследовано в [13]. В работе [14] выделены два основных направления изучения фрактальности психологических феноменов: изучение особенностей восприятия фрактальных объектов; анализ фрактальных особенностей психологического функционирования, в том числе сложных социальных взаимодействий. С позиций фрактального подхода здоровье имеет все признаки фрактальной структуры, которая выступает в виде единого целого, имплицитно содержащего в себе возможные траектории развития составляющих ее фракталов, их проявлений и базовых доминант [15]. В [16] рассмотрена возможность применения фрактального принципа самоподобия для выявления влияния индивидуального годичного ритма на процессы жизнедеятельности человека, исследовано состояние психической активности как свойства психики к воспроизведению одних и тех же структур на разных уровнях ее целостности. Фрактальный подход к процессу саморазвития педагога, в котором определена фрактальная организация процесса личностно-профессионального саморазвития в интегративной образовательной среде, разработана классификация фракталов как самого процесса саморазвития, так и среды, предложены в [17]. В работе [18] рассмотрен метод фрактального анализа цифровой обработки записей ЭЭГ для определения патологических состояний, связанных с эпилепсией. Методы вызванных потенциалов, спектральной мощности и фрактальности ЭЭГ использовались в [19] для исследования различий в восприятии своего и чужого лица. Таким образом, фрактальные модели успешно применяются для анализа нейрофизиологических процессов и субъективных состояний, связанных с мозговой активностью [20].

В работах [21, 22] показано, что существует связь между способностью к саморегуляции и психологическим типом личности. Для оценки результатов саморегуляции использовано число значимых значений коэффициентов корреляции между физиологическими и психофизиологическими показателями, изменяющимися в результате осознанной деятельности субъекта с мысленными образами во внутреннем пространстве. Показатели меры субъектности построены на основе результатов тестирования, использующих опросники Кейрси и «Диагностика субъектности» Е.Н. Волковой. Эти показатели отличаются для мужчин и женщин, для экстравертов и интровертов. Способность к саморегуляции возрастает с увеличением меры субъектности приблизительно линейно. Таким образом, подтверждается концепция [23], согласно которой воздействие сознания субъекта изменяет энергоинформационный обмен в организме, отражающийся в функционировании его органов и систем. Уровень субъектности определяется в большей степени уровнем эволюции сознания.

Гипотеза исследования: активность физических процессов в мозге имеет фрактальную природу, поэтому изменение физиологических и психофизиологических показателей в результате осознанной деятельности субъекта с мысленными образами подчиняется фрактальным законам.

Цель исследования – определить фрактальные параметры изменения физиологических и психофизиологических показателей в результате процессов саморегуляции.

Объект исследования – субъекты учебной деятельности, работающие по программе психофизической саморегуляции.

Предмет исследования – процесс влияния активности ритмов мозга на успешность овладения техникой саморегуляции.

В исследовании приняли участие 25 человек (18 мужчин, 7 женщин) в возрасте от 20 до 23 лет. Все участники исследования были проинформированы о его цели и проинструктированы о методиках тестирования. Методика исследования включала шесть этапов: 1 – предварительное измерение (определение начального функционального и психоэмоционального состояния испытуемых с

помощью аппаратно-программного диагностического комплекса (АПДК) Silver Step Pulse); 2 – стимуляцию (методически организованный сеанс саморегуляции); 3 – определение функционального и психоэмоционального состояния испытуемых после сеанса саморегуляции; 4 – психологическое тестирование; 5 – обработку результатов измерений, полученных с помощью Silver Step Pulse; 6 – анализ результатов исследований. Длительность сеансов саморегуляции составляла $10 \div 20$ минут. Применялись следующие психотехники аутотренинга, направленные на регуляцию физиологических параметров: абдоминальное дыхание, концентрация сознания на энергетических центрах, кокон, дыхание в мозг и другие.

Для объективных измерений динамики состояний: вегетативной нервной системы, нейрогуморальной регуляции, психоэмоционального состояния, спектрограммы головного мозга и других показателей использовался метод кардиоинтервалографии (КИГ), реализованный в АПДК Silver Step Pulse. КИГ применяется для исследования психофизиологической саморегуляции, отражаемой в базальной вариабельности сердечного ритма.

Из всех показателей функционального состояния организма, определяемых АПДК Silver Step Pulse, выбраны 15 показателей: из них 5 характеризуют активность ритмов мозга x_{ik} $i = 1, 2 \dots 5$ (дельта-, тета-, альфа-, бета-, гамма-ритмы), 10 – функциональное состояние y_{jk} $j = 1, 2 \dots 10$ (индексы адаптации, напряженности, вегетативного равновесия, ресурсов организма, энергетического баланса, психоэмоционального состояния, гармонизации биоритмов, вегетативной регуляции, нейрогуморальной регуляции, комплексный показатель здоровья), $k = 1, 2, \dots 25$ – номер респондента.

Для психологического тестирования использовались опросник Кейрси, опросник «Диагностика субъектности» Е.Н. Волковой, опросник «Самоактуализации личности» А.В. Лазукина в адаптации Н.Ф. Калина.

Опросник Кейрси содержит четыре биполярные шкалы, отображающие содержание восьми психологических факторов темперамента:

1. Шкала Е-І – ориентация сознания: Е (экстраверсия), (І интроверсия).

2. Шкала S-N – способ ориентировки в ситуации: S (здравый смысл), N (интуиция).
3. Шкала T-F – основа принятия решений: T (мышление), F (чувство).
4. Шкала J-P – способ подготовки решений: J (суждение), P (восприятие).

В тесте «Диагностика субъектности» Е.Н. Волковой использовались 6 шкал: осознанная активность, способность к рефлексии, свобода выбора и ответственность за него, осознание собственной уникальности, понимание и принятие других, саморазвитие.

В тесте Самоактуализации использовались 5 шкал: взгляд на природу человека, потребность в познании, креативность, автономность, самопонимание.

Обозначим показатели тестирования по каждой из шкал для респондента с номером $k = 1, 2, \dots, 25$: экстраверсия – e_k , интроверсия – i_k , здравый смысл – s_k , интуиция – n_k , мышление – t_k , чувство – f_k , суждение – j_k , восприятие – p_k , осознанная активность – a_k , способность к рефлексии – r_k , свобода выбора и ответственность за него – c_k , осознание собственной уникальности – u_k , понимание и принятие других – b_k , саморазвитие – d_k , взгляд на природу человека – v_k , потребность в познании – w_k , креативность – q_k , автономность – h_k , самопонимание – l_k .

Определим закономерности изменения показателей функционального состояния организма и психологического тестирования, используя корреляционный анализ.

Изменение состояния респондентов определялось по изменению показателей активности мозга и функционального состояния в результате сеансов саморегуляции. Наличие механизмов саморегуляции организма должно приводить к каким-либо закономерностям во взаимном изменении этих показателей. Поэтому для данных каждого респондента рассчитывались коэффициенты корреляции Пирсона $rc(y_{jk}, x_{ik})$ для каждой пары показателей, из которых один или оба характеризуют активность мозга. Коэффициенты корреляции считался значимым, если показатель достоверности $p < 0,05$. Для каждого респондента с номером k определялось число m_k и доля $pm_k = m_k/m_0$ значимых корреляций, где m_0 – число раз-

личных пар выбранных показателей АПДК Silver Step Pulse. Значение pm_k характеризует успешность процессов саморегуляции каждого субъекта и, таким образом, является объективной оценкой достигнутого результата.

В работах [21, 22] для каждого респондента мера субъектности определялась как суперпозиция показателей двух тестов. В данной работе использовались три теста. Для исследуемой группы рассчитывались коэффициенты корреляции Пирсона для всех пар: успешность процессов саморегуляции, показатели шкал психологического тестирования. Учитывались коэффициенты корреляции $rc > rp$ ($rp = 0,396$, $p = 0,05$, $n = 25$). С показателем успешности процессов саморегуляции pm коррелируют только показатели шкал r (способность к рефлексии) и h (автономность): $rc(pm, r) = -0,438$, $rc(pm, h) = -0,428$ (обратная корреляция). Способность к рефлексии и автономность коррелируют между собой $rc(r, h) = 0,519$, $p < 0,01$.

Рассмотрим пары y_{jk} , x_{ik} для каждого респондента, имеющие значимые коэффициенты корреляции. Чтобы определить фрактальную размерность для изменения физиологических и психофизиологических показателей в результате процессов саморегуляции, нормируем значения каждого показателя y_{jk} , x_{ik} . Для этого используем линейное отображение $x'_{ik} = F_{ik}(x_{ik})$, $y'_{jk} = F_{jk}(y_{jk})$ в отрезок $[0, 1]$. Линейное преобразование переменных не изменяет коэффициент корреляции. Построим на значениях x'_{ik} степенные функции $y''_{jik} = (x'_{ik})^{\zeta_{jik}}$. Показатель степени ζ_{jik} (фрактальная размерность) обеспечивает максимальное значение коэффициента корреляции $rc(y'_{jk}, y''_{jik})$, которое оказывается больше, чем $rc(y_{jk}, x_{ik})$. Пример полученных зависимостей для одного из респондентов показан на рис. 1 – рис. 4 в нормированных величинах, где точки – эксперимент, линия – степенная функция.

Коэффициент корреляции и фрактальная размерность ($p < 0,05$): рис. 1 – $rc = 0,607$, $\zeta = 1,78$; рис. 2 – $rc = 0,598$, $\zeta = 1,4$; рис. 3 – $rc = 0,599$, $\zeta = 1,16$; рис. 4 – $rc = 0,60$, $\zeta = 1,11$. Коэффициенты корреляции с участием α -ритма дают аналогичные результаты, но $0,05 < p < 0,1$. Значения фрактальной размерности соответствуют данным [14] и объясняются фрактальностью структур и функций мозга и нерв-

ной системы в целом. Фрактальные параметры каждого респондента индивидуальны, однако прослеживается сложная связь с физиологическими характеристиками и типом личности, что является предметом дальнейших исследований.




Рис. 1. Зависимость показателя адаптации от активности β -ритма:




Рис. 2. Зависимость комплексного показателя здоровья от активности β -ритма




Рис. 3. Зависимость показателя нейрогуморальной регуляции от активности β -ритма




Рис. 4. Зависимость психоэмоционального состояния от активности β -ритма

Заключение

В работе [24] построена фрактально-структурная информационная модель организма человека. Фрактал выступает основой хранения и передачи информации в организме. Фрактал формируется специфически на клеточном уровне органов. Нейронная сеть мозга, функциональные системы организма – примеры реализации фрактала.

В данной работе под фракталом понимается структура, строящаяся из са-

моподобных элементов, но не имеющих заданной геометрической формы. Устойчивый или квазиустойчивый фрактал реализуется посредством самосогла-сованного взаимодействия биологических структур, использующего электриче-ские, электромагнитные, акустические, механические, химические и другие про-цессы. Обобщая совокупность свойств организма, в интегральном смысле ис-пользуем термин психофизический фрактал (ПФФ). ПФФ имеет как геометриче-скую, так и полевую структуру.

В различных методах исследования (ЭЭГ, ЭКГ, КИГ, ФКГ, фМРТ и др.) наблюдаются различные свойства ПФФ. Внешние воздействия (электрические, электромагнитные, акустические, механические и другие) могут восстанавливать или выводить ПФФ из состояния равновесия.

С этой точки зрения саморегуляция как методика управления своим пси-хофизиологическим состоянием, использующая аффирмации, мыслеобразы, ре-гулирование мышечного тонуса и дыхания, а также другие воздействия, направ-ленные на трансформацию отдельных функций психики и нервно-психических реакций, воздействует через полевою составляющую ПФФ как на отдельные ор-ганы, так и на организм в целом.

Список литературы

1. Орлов В.А. Исследования в парадигме сокрытия информации: оценка фМРТ-данных на групповом уровне / В.А. Орлов, С.И. Карташов, Д.Г. Малахов и др. // Экспериментальная психология. — 2024. — Т. 17. — № 1. — С. 86 – 107.
2. Novoa R.F. Correlation between emotional state and functional activation with magnetic resonance imaging / R.F. Novoa, I.B. Ceressa, M.A. Oliva, et al // Rev Argent Radiol. — 2023. — V. 87. — I. 2. — P. 45 – 53.
3. Tsolakis A.C. Electroencephalography classification of healthy, mild cognitive impairment and probable Alzheimer's disease through linear and non-linear biomarkers / A.C. Tsolakis, C. Timplalexis, M. Tsolaki, et al. // Medical Research Archives. — 2022. — V. 10. — I. 9. — P. 1 – 20.

4. Portillo-Lara R. Mind the gap: State-of-the-art technologies and applications for EEG-based brain–computer interfaces / R. Portillo-Lara, Bogachan Tahirbegi, C.A.R. Chapman, et al. // *APL Bioengineering*. — 2021. — V. 5(031507).
5. Bechtel W. Situating homeostasis in organisms: maintaining organization through time / W. Bechtel, L. Bich // *The Journal of Physiology*. — 2024. — V. 602.22. — P. 6003–6020.
6. Wilson D.F. Metabolic Homeostasis in Life as We Know It: Its Origin and Thermodynamic Basis / D.F. Wilson, F.M. Matschinsky // *Front. Physiol.* — 2021. — V. 12(658997).
7. Konieczny L. Regulation in Biological Systems / L. Konieczny, I. Roterman-Konieczna, P. Spólnik // *Systems Biology. Functional Strategies of Living Organisms*. — Springer Nature Switzerland. — 2023. — P. 159–203.
8. Баратова Г.К. Применение функциональной МРТ в оценке когнитивных расстройств и ранней диагностики нейродегенеративных заболеваний / Г.К. Баратова, Я.А. Ахмедов // *Progress of Science: Theory and Practice*. — 2025. — V. 2. — I. 1. — P. 41-47.
9. Еремин А.Л. Нейрофизическая программируемая модель визуализации локусов умственных функций в мозге / А.Л. Еремин, Н.М. Богатов, А. Рейес Монкада // *Биомедицинская радиоэлектроника*. — 2025. — Т. 28. — № 1. С. 6 – 17.
10. Novoa R.F. Correlation between emotional state and functional activation with magnetic resonance imaging / R.F. Novoa, I.B. Ceressa, M.A. Oliva, P.D. Páez // *Argentine journal of radiology*. — 2023. — V. 87. — I. 2. — P. 45 – 53.
11. Yumatov E.A. Psychogenic theory of consciousness / E.A. Yumatov // *Medical Research Archives*. — 2021. — V. 9. — I. 5. — P. 1 – 21.
12. Еремин А.Л. Ноогенез и теория интеллекта / А.Л. Еремин. – Краснодар: «Советская Кубань», 2005. — 356 с.

13. Ткачева Л.О. Воздействие фрактальных динамических изображений на функциональное состояние человека / Л.О. Ткачева // Вестник СПбГУ. — 2010. — Сер. 12. — Вып. 2. — С. 378 – 387.
14. Пьянкова С.Д. Фрактально-аналитические исследования в психологии: особенности восприятия самоподобных объектов / С.Д. Пьянкова // Психологические исследования. — 2016. — Т. 9. — № 46. — С. 12 – 25.
15. Маджуга А.Г. Здоровье человека как многомерный феномен: фрактальный подход / А.Г. Маджуга, И.А. Синицина, Л.Н. Уварова // Журнал научных статей “Здоровье и образование в XXI веке”. — 2015. — Т. 17. — № 4. — Р. 292 – 298.
16. Гребнева В.В. Фрактальная организация биоритмов как основа взаимосвязи индивидуальных циклов психической активности человека / В.В. Гребнева, Д.Е. Стариченко // Научный результат. Педагогика и психология образования. — 2018. — Т. 4. — В. №1. — С. 65 – 82.
17. Ушаков А.А. Фрактальная методология личностно-профессионального саморазвития педагога в интегративной образовательной среде / А.А. Ушаков // Мир науки. Педагогика и психология. — 2020. — Т. 8. — № 2. — С. 1 – 12.
18. Егорова Л.Д. Методы фрактального анализа ЭЭГ-сигнала для диагностики эпилептических расстройств / Л.Д. Егорова // Актуальные проблемы авиации и космонавтики. — 2021. — Т. 2. — С. 138 – 140.
19. Портнова Г.В. Различия ЭЭГ при восприятии своего и чужого лица: применение комплексного подхода к анализу данных ЭЭГ / Г.В. Портнова, Л.Б. Окнина, Е.Л. Машеров и др. // Журнал высшей нервной деятельности им. И.П. Павлова. — 2022. — Т. 72. — № 4. — С. 576 – 586.
20. Мачурина Т.Н. Теория хаоса и фракталы в психотерапии и клинико-психологическом консультировании / Т.Н. Мачурина // Математическое образование. — 2022. — В. 2(102). — С. 38 – 42.
21. Богатов Н.М. Способность управления состоянием организма мужчин и женщин / Н.М. Богатов, А.Н. Богатова, С.А. Сухих // Нейроинформатика, её

- приложения и анализ данных: Материалы XXXI Всероссийского семинара. Красноярск: Институт вычислительного моделирования СО РАН. — 2023. — С. 13 – 20.
22. Богатов Н.М. Влияние психологических особенностей субъектов на результативность процессов саморегуляции / Н.М. Богатов, А.Н. Богатова, А.Л. Еремин, С.А. Сухих // Нейроинформатика, её приложения и анализ данных: Материалы XXXII Всероссийского семинара. Красноярск: Институт вычислительного моделирования СО РАН. — 2024. — С. 27 – 36.
23. Сухих С.А. Условия успеха саморегулятивной практики / С.А. Сухих, Н.М. Богатов, А.Н. Богатова // Приверженность вопросам психического здоровья: материалы III Международной научно-практической конференции. / под ред. О.Б. Михайловой, Е.Б. Башкина. – Москва: РУДН. — 2022. — С. 103 – 109.
24. Росман С.В. Фрактальная теория деятельности центральной нервной системы и морфогенез внутренних органов/ С.В. Росман, В.П. Волков // Universum: Медицина и фармакология. — 2015. — № 1. — С. 1 – 14.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ПАРАМЕТРОВ БУРЕНИЯ НЕФТЕГАЗОВОЙ СКВАЖИНЫ

А.В. Волоснев¹, П.В. Гуров¹, И.А. Абрамов², А.С. Родченко², В.И. Горбаченко²

¹АО Дриллматик, Москва, *av@drillmatic.ru, pg@drillmatic.com*

²Пензенский государственный университет,
факультет вычислительной техники,
кафедра Компьютерные технологии, *igora379@gmail.com, rodchenko-aleksandr01@mail.ru, gorvi@mail.ru*

Введение. Бурение является одной из важнейших операций в нефтяной промышленности и представляет собой дорогой и сложный инженерно-технологический процесс. Важнейшим фактором процесса бурения является скорость проходки бурения, непосредственно влияющая на время бурения и затраты. Поэтому важен прогноз скорости проходки бурения. Однако, в попытке достичь высоких показателей, нередко возникают различные проблемы и аварии [1], обусловленные неточным прогнозированием параметров бурения. Например, прихват бурильной колонны происходит из-за неправильного прогноза нагрузки на долото или частоты вращения буровой колонны. Неточный прогноз давления на устье может привести к выбросу. Точное прогнозирование нагрузки на долото, частоты вращения буровой колонны, давления на устье скважины и других параметров давления косвенно повышает скорость проходки и снижает затраты на строительство скважины.

Современные буровые установки оборудованы большим количеством различных датчиков. Многие параметры бурения зависят друг от друга, и изобилие датчиков позволяет контролировать качество поступающих данных. Таким образом, большая часть процессов бурения может быть представлена в виде числовых показателей во времени. Для математического представления такого рода данных используется понятие временного ряда.

В большинстве случаев в настоящее время в бурении используются физи-

ко-математические модели, описывающие механику и гидравлику, так называемый цифровой двойник [2–4]. Эти модели необходимы буровому инженеру для оценки ситуации в настоящий момент времени. Для оценки будущего поведения системы необходимо предсказать значения по параметрам, которые приходят с датчиков. Совокупность каждого из этих параметров представляет собой временной ряд.

Прогнозирование временных рядов — это важная задача в различных областях, таких как экономика, финансы, метеорология и здравоохранение [5]. Традиционно для решения этой задачи использовались методы статистического анализа, такие как авторегрессионные модели (AR), скользящие средние (MA) и их комбинации (ARIMA). Эти методы хорошо зарекомендовали себя на практике, однако они имеют свои ограничения, особенно когда речь идет о сложных и нелинейных зависимостях в данных.

Процесс бурения зависит от множества факторов, начиная с геологии и траектории и заканчивая человеческим фактором. Даже характер бурового мастера или культура организации могут быть отпечатаны в данных. Поэтому классические методы статистического анализа плохо подходят для прогнозирования параметров бурения. Для прогнозирования параметров бурения перспективны глубокие нейронные сети [6–7].

Целью данной работы является прогнозирование параметров бурения с помощью глубоких нейронных сетей.

1. Материалы и методы. Применение нейронных сетей для прогнозирования параметров бурения в виде временных рядов получило широкое распространение благодаря их способности моделировать нелинейные связи и временные зависимости, которые присущи буровым работам. Большинство опубликованных работ, которые посвящены данной проблеме, описывают построение моделей нейронных сетей для прогнозирования как правило скорости проходки бурения, в то время как выполнение прогноза других параметров, оказывающих влияние на процесс бурения, не рассматривается. В отличие от известных работ

авторами с помощью методов глубокого обучения реализовано прогнозирование следующих параметров бурения, оказывающих существенное влияние на процесс бурения:

- Well Depth (m) — глубина скважины;
- Bit Depth (m) — глубина долота;
- Weigth on Bit (tf) — нагрузка на долото;
- SPP (atm) — давление на устье;
- FlowRate In (l/sec) — скорость потока на выходе;
- Surface Torque (kN-m) — момент на роторе;
- Surface RPM (rpm) — обороты буровой колонны;
- Block Position (m) — позиция талевого блока;
- Tripping Speed (m/s) — скорость подъёмно-спусковых операций;
- ROP (m/hr) — скорость проходки бурения.

Каждый представленный параметр, изменяющийся во времени, представляется собой временной ряд, который является объектом анализа и прогнозирования.

Для прогнозирования временных рядов применяют разные типы нейронных сетей (полносвязные, сверточные, рекуррентные, а также их комбинации) [5]. Нейронные сети, построенные на основе полносвязных слоёв, дают хорошие результаты при прогнозировании последовательностей, в которых наблюдается цикличность. Также хороших показателей обучения при прогнозировании временных рядов обеспечивают нейронные сети на основе рекуррентных и одномерных сверточных слоёв.

Рекуррентные нейронные сети специально разработаны для обработки последовательностей, каковыми могут быть предложения текста естественного языка и временные ряды. Рекуррентная нейронная сеть представляет собой модель, в которой выходные данные сети на одном временном шаге предоставляются в качестве входных данных на последующем временном шаге. Это позволяет модели принимать решение о том, как прогнозировать, основываясь как на входных данных для текущего временного шага, так и на прямом знании того,

что было получено на предыдущем временном шаге [8]. Особенно большей популярностью пользуется слой долгой краткосрочной памяти, или сокращенно LSTM. Слои LSTM помимо использования рекуррентного соединения выходов предыдущего временного шага, также имеют внутреннюю память, которая работает как локальная переменная, позволяя накапливать состояние по входной последовательности.

Сверточные нейронные сети содержат слои, в которых выполняется свертка обучаемых данных с помощью настраиваемого фильтра. Сверточные сети использовались для двумерных данных, нашли свое применение в обработке изображений. Одномерную модель сверточной сети можно применить и для одномерных данных, таких как последовательности текста и временные ряды. Одномерная сверточная сеть имеет скрытый сверточный слой, который работает с одномерной последовательностью. В некоторых случаях за ним, возможно, следует второй сверточный слой, например, при очень длинных входных последовательностях, а затем слой объединения. За сверточными слоями и слоями объединения следует полносвязный слой, который интерпретирует функции, извлеченные с помощью сверточной части модели. Сглаживающий слой используется между сверточными слоями и полносвязным слоем, чтобы свести карты объектов к одному одномерному вектору [9].

Большие перспективы использования для прогнозирования временных последовательностей имеет архитектура нейронной сети со сверточными одномерными слоями. В [10] предложена архитектура сети для обработки аудиоданных, построенная в виде стопки одномерных расширенных сверточных слоёв (Dilated Convolution) с нарастающими степенями растяжения (dilation rate). Данный подход построения архитектуры нейронной сети был применён для прогнозирования временных рядов.

Используемая архитектура сети состояла из 12 подряд идущих одномерных сверточных слоёв. Первые 11 слоёв имели растущие степени расширения 1, 2, 4, ..., 1024. Каждый слой имеет 128 фильтров, размер сверточного ядра 2, функцию активации ReLU и дополнение «causal». Данный вид дополнения при-

водит к причинно-следственным свёрткам, когда предсказанное значение на текущем шаге не зависит от входных данных следующего временного шага. У последнего свёрточного слоя количество фильтров равно горизонту прогнозирования.

Для выполнения многошагового прогнозирования применялась прямая стратегия, строящая для каждого расширенного горизонта прогноз на основе прошлых значений. Для прямой стратегии прогнозирования целевые данные формируются с учётом выбранного горизонта прогноза.

Весь набор данных был разделён на три части (тренировочные, проверочные и тестовые данные) в соотношении 70%, 20% и 10 %. Перед использованием данных для обучения нейронной сети была выполнена их нормализация

$$x_{\text{норм}} = \frac{x - \bar{x}}{\sigma},$$

где x — текущие обрабатываемые данные, $\bar{x}$ — среднее значение, σ — среднее квадратическое отклонение.

При обучении нейронной сети использовался оптимизатор Adam с постоянной скоростью обучения. Контроль процесса обучения осуществлялся с помощью функции потерь, в качестве которой была использована среднеквадратическая ошибка (MSE). При тестировании модели сети выбраны метрики корень от среднеквадратической ошибки (RMSE) и коэффициент детерминации (R^2). Максимально для обучения было определено 200 эпох, однако обучение прерывалось, когда процесс переходил в состояние переобучения, при этом в файле сохранялась модель с оптимально настроенными весовыми коэффициентами. Впоследствии, из файла сохранённая модель загружалась для выполнения прогноза.

2. Результаты. С помощью обученной модели нейронной сети были сделаны прогнозы параметров бурения на основе данных из тестовой выборки. На рис. 1 представлен результат предсказания параметров бурения «Нагрузка на долото», «Обороты буровой колонны», «Давление на устье» и «Скорость проходки бурения». Как видно из представленных на рис. 1 графиков разница между фактическими и предсказанными значениями невелика. Наибольшая разница

наблюдается при предсказании параметра «Обороты буровой колонны» ($RMSE = 0.3639$, $R^2 = 0.8198$). Лучше предсказаны параметры «Давление на устье» и «Скорость проходки бурения». Здесь значения метрик $RMSE$ и R^2 составили соответственно 0.4304 и 0.9401 при прогнозировании «Давление на устье» и 0.2499 и 0.9657 при предсказании параметра «Скорость проходки бурения». Значения метрик предсказания $RMSE$ и R^2 всех прогнозируемых параметров представлены в таблице.




Рис. 1 Графическое представление действительных и спрогнозированных значений

А Weigth on Bit (tf) — нагрузка на долото; Б Surface RPM (rpm) — обороты буровой колонны; В SPP (atm) — давление на устье; Г ROP (m/hr) — скорость проходки бурения.

Таблица.

Значения RMSE и R^2 прогнозирования параметров бурения

Прогнозируемый параметр	Значение RMSE	Значение R^2
глубина скважины	0.0054	0.9740
глубина долота	0.0128	0.9884
нагрузка на долото	0.1869	0.9228
давление на устье	0.4304	0.9401
скорость потока на выходе	0.2527	0.9204
момент на роторе	0.2415	0.8209
обороты буровой колонны	0.3639	0.8198
позиция талевого блока	0.1141	0.8936
скорость подъёмно-спусковых операций	0.4650	0.6398
скорость проходки бурения	0.2499	0.9657

На рис. 2 представлены изменения функции потерь при обучении параметров «Нагрузка на долото», «Обороты буровой колонны», «Давление на устье» и «Скорость проходки бурения» для тренировочных и проверочных данных. Данные формировались для временного окна 600 и горизонта прогноза 120 временных шагов.

3. Обсуждение. Полученные значения коэффициента детерминации показывают, что модель достаточно точно воспроизводит тренды, что важно для контроля технологического процесса. Одновременное прогнозирование 10 ключевых параметров позволяет оценивать не только скорость проходки, но и комплекс факторов, которые влияют на риски при бурении. Это создает основу для более глубокой аналитики осложнений.




Рис. 2. Потери на этапах обучения и проверки модели

А Weight on Bit (tf) — нагрузка на долото; Б Surface RPM (rpm) — обороты буровой колонны; В SPP (atm) — давление на устье; Г ROP (m/hr) — скорость проходки бурения.

Модель имеет некоторые ограничения. Например, прогнозы по скорости проходки и по оборотам буровой колонны хорошо показывают тренд, но менее точно предсказывают значения параметров, что может быть критичным при прогнозировании осложнений, связанных с прихватами или динамическими нагрузками.

Заключение

Применение нейронных сетей для прогнозирования параметров бурения показало высокую перспективность и практическую ценность. Модели позволяют прогнозировать не только скорость проходки, но и комплекс параметров, которые формируют картину состояния скважины в режиме реального времени.

Это открывает возможности для: прогнозирования осложнений (прихваты, аномалии давления, гидравлические удары) на ранних стадиях; оптимизации режимов бурения, что напрямую влияет на экономику строительства скважины; использования таких моделей как элементов интеллектуального автопилота (Автобурение), управляющего процессом бурения автоматически; построения цифровых двойников скважины, которые будут не только описывать текущее состояние, но и предсказывать развитие ситуации.

Следует подчеркнуть, что нейросетевые модели не заменяют инженера, а дополняют его, предоставляя инструмент для быстрой оценки рисков и поддержки принятия решений.

Для внедрения в промышленную практику необходимы:

- адаптация моделей к данным разных регионов и геологических условий,
- повышение устойчивости к шумным и неполным данным,
- интеграция с существующими системами мониторинга и управления бурением.

Таким образом, нейросетевое прогнозирование можно рассматривать как важный шаг в развитии интеллектуальных систем управления строительством скважин, направленных на снижение аварийности, ускорение бурения и оптимизацию затрат.

Список литературы

1. 11 Common Drilling Challenges and How To Solve Them.

E-print: <https://www.petrosync.com/blog/drilling-challenges/>

2. Алексеев О.О. Цифровой двойник: как технология создания виртуальной скважины помогает повысить эффективность строительства / О.О. Алексеев, П.Э. Востриков // Бурение & нефть. — 2023. — № 5.

E-print: https://burneft.ru/archive/issues/detail.php?ELEMENT_ID=63277

3. Karpov R. Live Digital Twin Improving Drilling Performance and Providing Foundation for the Realtime Data Quality Control / R. Karpov, N. Kojadinovic.

- U. Kokotovic, K. Zakirov, K. Valiullin // Abu Dhabi International Petroleum Exhibition & Conference (ADIPEC). — 2023. — Paper Number: SPE-216981-MS. doi: 10.2118/216981-MS
4. Saini G.S. Digital Twins for Real-Time Scenario Analysis during Well Construction Operations / G.S. Saini, A. Fallah, R. Ashok, R; E. van Oort // *Energies*. — 2022. — Vol. 15. — No. 18. — Article number 6584. doi: 10.3390/en15186584
5. Нильсен Э. Практический анализ временных рядов: прогнозирование со статистикой и машинное обучение. — СПб.: ООО Диалектика, 2021. — 544 с.
6. Shaohu L. Prediction of drilling plug operation parameters based on incremental learning and CNN-LSTM / L. Shaohu, W. Yuandeng, H. Rui // *Geoenergy Science and Engineering*. — 2024. — Vol. 234, No. 3. — Article number 212631. doi: 10.1016/j.geoen.2024.212631
7. Bai K. Drilling Rate of Penetration Prediction Based on CBT-LSTM Neural Network / K. Bai, S. Jin, Z. Zhang, S. Dai // *Sensors*. — 2024. — Vol. 24. No. 21. Article number 6966. doi: 10.3390/s24216966
8. Peixeiro M. Time Series Forecasting in Python. — N.Y.: Manning, 2022. — 456 p.
9. Joseph M. Modern Time Series Forecasting with Python: Industry-ready machine learning and deep learning time series analysis with PyTorch and pandas / M. Joseph, J. Tackes. — Birmingham: Packt Publishing, 2024. — 660 p.
10. van den Oord A. WaveNet: A Generative Model for Raw Audio / A. van den Oord, S. Dieleman, H. Zen, K. Simonyan, O. Vinyals, A. Graves, N. Kalchbrenner, A. Senior, K. Kavukcuoglu. E-print: <https://arxiv.org/abs/1609.03499>

ПРИМЕНЕНИЕ МЕТОДА УПРУГИХ (ЭЛАСТИЧНЫХ) КАРТ ДЛЯ ВИЗУАЛИЗАЦИИ ДАННЫХ В КАРДИОЛОГИИ

С.Е. Головенкин, И.В. Савицкий

Красноярский Государственный медицинский университет,

кафедра факультетской терапии, *gse2008@mail.ru*

Совершенствование лечения заболеваний сердечно-сосудистой системы является важнейшей задачей системы здравоохранения любого государства. В течение многих лет ишемическая болезнь сердца является главной причиной смертности населения в большинстве экономически развитых странах мира. Инфаркт миокарда - наиболее грозное её проявление, нередко приводящее к летальным исходам. В последние десятилетия некоторый рост заболеваемости инфарктом миокарда (ИМ), остается на высоком уровне и смертность от него [1-3]. Это заставляет искать новые подходы к профилактике, лечению и реабилитации больных с данным заболеванием. Для решения этих задач необходимо, в частности, совершенствование методов прогнозирования течения и исходов острого ИМ.

Ранее для прогнозирования осложнений острого инфаркта миокарда мы применяли компьютерные нейронные сети, позволяющие получить достаточно высокие показатели чувствительности и специфичности прогноза [4-6]. В последние 25-30 лет для решения многих вопросов (в том числе и для прогнозирования) в медицине активно применяется метод визуализации с использованием упругих (эластичных) карт [7-9]. Методика эластичных упругих карт позволяет визуализировать результаты, полученные в результате клинических исследований. Под визуализацией данных авторы методики [7] понимают такой способ представления многомерного распределения данных на двумерной плоскости, при котором, по крайней мере, качественно отражены основные закономерности, присущие исходному распределению - его кластерная структура, топологические особенности, внутренние зависимости между признаками, информация о расположении данных в исходном пространстве и

т.д. В качестве основных применений методов визуализации можно указать следующие:

- а) наглядное представление геометрической метафоры данных;
- б) лаконичное описание внутренних закономерностей, заключенных в наборе данных;
- в) сжатие информации, заключенной в данных;
- г) восстановление пробелов в данных;
- д) решение задач прогноза и построения регрессионных зависимостей между признаками.

Методика визуализация с использованием упругих карт стала популярна и достаточно часто использовалась в кардиологии, эндокринологии и других разделах внутренних болезней [7-10]. Очень важным аспектом является то, что данная методика как активно использовалась для решения практических задач в медицине [11-15], так и динамично совершенствовалась авторами [16-17].

Анализ литературы позволяет сделать вывод, что метод визуализации данных с построением упругих (эластичных) карт может с успехом применяться в различных областях кардиологии. Применение нового метода может позволить получить дополнительную информацию о течении основного заболевания и возможном развитии осложнений. Применение этих знаний на практике может помочь вовремя применить необходимые профилактические мероприятия, предотвратив возникновение тяжелых осложнений. Это в свою очередь улучшит качество оказания помощи кардиологическим больным и прогноз заболевания у пациентов с данной патологией.

СПИСОК ЛИТЕРАТУРЫ

1. 2021 Рекомендации ESC по диагностике и лечению острой и хронической сердечной недостаточности. Российский кардиологический журнал. 2023;28(1):5168. doi:10.15829/1560-4071-2023-5168. EDNSJMIKK.

2. 2020 Clinical practice guidelines for Acute ST-segment elevation myocardial infarction. Russian Journal of Cardiology. 2020;25(11):4103. (In Russ.) Острый инфаркт миокарда с подъемом сегмента ST электрокардиограммы. Клинические рекомендации 2020. Российский кардиологический журнал. 2020;25(11):4103. doi:10.15829/1560-4071-2020-4103.
3. 2020 ESC Guidelines for the management of acute coronary syndromes in patients presenting without persistent ST-segment elevation Russian Journal of Cardiology. 2021;26(3):4418. (In Russ.) Рекомендации ESC по ведению пациентов с острым коронарным синдромом без стойкого подъема сегмента ST 2020. Российский кардиологический журнал. 2021;26(3):4418. doi:10.15829/1560-4071-2021-4418.
4. Россиев Д.А., Головенкин С.Е., Шулман В.А., Матюшин Г.В. Прогнозирование осложнений инфаркта миокарда нейронными сетями. // Нейроинформатика и ее приложения. Материалы III Всероссийского рабочего семинара. 6-8 октября 1995 г. Красноярск.- 1995.- С.128-166.
5. Gorban A.N., Rossiev D.A., Butakova E.V., Gilev S.E., Golovenkin S.E., Dogadin S.A., Dorrer M.A., Kochenov D.A., Kopytov A.G., Maslennikova E.V., Matyushin G.V., Mirkes Ye.M., Nazarov B.V., Nozdrachev K.G., Savchenko A.A., Smirnova S.V., Shulman V.A., Zenkin V.I. Medical, psychological and physiological applications of MultiNeuron neural simulator // The Second International Symposium on Neuroinformatics and Neurocomputers, Rostov-on-Don, Russia, September 20-23, 1995.- Rostovon-Don, 1995.- P.7-14.
6. Gorban A.N., Rossiev D.A., Gilev S.E., Dorrer M.G., Kochenov D.A., Mirkes Ye.M., Golovenkin S.E., Dogadin S.A., Nozdrachev K.G., Matyushin G.V., Shulman V.A., Savchenko A.A. Medical and physiological applications of MultiNeuron neural simulator // Proc. WCNN 95. (World Congress on Neural Networks 95). - Washington, DC, July 1995.
7. Зиновьев А.Ю. Визуализация многомерных данных. - Красноярск: Изд-во КГТУ, 2000. - 168 с
8. A. Zinovyev, ViDaExpert - Multidimensional Data Visualization Tool (free for non-commercial use). Institut Curie, Paris.
9. A. N. Gorban, A. Y. Zinovyev, Principal Graphs and Manifolds, In: Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods and

Techniques, Olivas E.S. et al. Eds. Information Science Reference, IGI Global: Hershey, PA, USA, 2009. 28–59.

10. Resta M. Portfolio optimization through elastic maps: Some evidence from the Italian stock exchange, Knowledge-Based Intelligent Information and Engineering Systems, Apolloni B, Howlett RJ, Jain L. (eds.), Lecture Notes in Computer Science, Vol. 4693, Springer: Berlin – Heidelberg, 2010, 635-641. ISBN 9783540748274, doi:10.1007/978-3-540-74827-4-80.

11. Wang Y, Klijn JG, Zhang Y, et al. Gene expression profiles to predict distant metastasis of lymph-node-negative primary breast cancer. Lancet 365, 671–679 (2005). doi:0.1016/s0140-6736(05)17947-1.

12. Gorban AN, Zinovyev A. Principal manifolds and graphs in practice: from molecular biology to dynamical systems. International Journal of Neural Systems. Vol. 20, No. 3 (2010) 219–232. doi:10.1142/s0129065710002383.

13. Chacon M, Levano H, Allende H, et al. Detection of Gene Expressions in Microarrays by Applying Iteratively Elastic Neural Net, In: B. Beliczynski et al. (Eds.), Lecture Notes in Computer Sciences, Vol. 4432, Springer: Berlin – Heidelberg 2007, 355–363. ISBN: 9783540716297. doi:10.1007/978-3-540-71629-7-40.

14. Shaban H, Tavoularis S. Measurement of gas and liquid flow rates in two-phase pipe flows by the application of machine learning techniques to differential pressure signals. International Journal of Multiphase. Flow 67(2014), 106-117. doi:10.1016/j.ijmultiphaseflow.2014.08.012.

15. Resta M. Computational Intelligence Paradigms in Economic and Financial Decision Making. Series Intelligent Systems Reference Library. Volume 99. Springer International Publishing. Switzerland, 2016. ISBN 9783319214405, doi:10.1007/978-3-319-21440-5.

16. Zinovyev A. Data visualization in political and social sciences, In: SAGE "International Encyclopedia of Political Science", Badie, B., Berg-Schlosser, D., Morlino, L. A. (Eds.), 2011. ISBN 9781412994163.

17. Gorban AN, Zinovyev AY. Principal Graphs and Manifolds, In: Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods and Techniques, Olivas E.S. et al. Eds. Information Science Reference, IGI Global: Hershey, PA, USA, 2009. 28–59. doi:10.4018/978-1-60566-766-9.ch002.

РАЗРАБОТКА НЕЙРОСЕТЕВОЙ ПРОГНОСТИЧЕСКОЙ МОДЕЛИ ЦИФРОВОГО ДВОЙНИКА ПОКАЗАТЕЛЕЙ БИЗНЕС-ПРОЦЕССОВ

М.Г. Доррер

Сибирский государственный университет науки и технологий

им. М.Ф. Решетнева, г. Красноярск, пр. Мира, д.82, mdorrer@mail.ru

Аннотация

В статье представлена комплексная разработка цифрового двойника бизнес-процессов, основанная на применении нейросетевых моделей для прогнозирования ключевых показателей эффективности (KPI). Цифровой двойник реализует концепцию виртуального представления реальных организационных процессов, обеспечивая непрерывный сбор данных, анализ и генерацию прогнозов с высокой точностью. Модель использует исторические данные, включая атрибуты экземпляров процессов и измерения показателей, для обучения нейросетевых алгоритмов. В ходе исследования достигнута значительная мера детерминации $R^2 > 0,5$ для большинства показателей при средней абсолютной ошибке (MAE) менее 0,7 единиц измерения по 5-бальной шкале. Решение интегрирует методы предобработки данных, включая нормализацию StandardScaler, и архитектуру нейронных сетей с двумя скрытыми слоями по 128 нейронов, что обеспечивает сбалансированность между точностью и вычислительной эффективностью. Практическая значимость работы заключается в возможности применения цифрового двойника для оптимизации бизнес-процессов, снижения затрат и поддержки принятия управленческих решений на основе прогнозов. Результаты демонстрируют потенциал использования нейросетевых моделей в управлении процессами.

Ключевые слова: бизнес-процесс, цифровой двойник, нейронные сети, прогноз показателей

Введение

Концепция цифровых двойников (ЦД) активно развивается в различных предметных областях, обеспечивая возможность создания высокоточных про-

гностических моделей бизнес-процессов [1]. В контексте управления процессами цифровой двойник представляет собой виртуальную модель, которая непрерывно обновляется данными из реальной системы и позволяет прогнозировать ключевые показатели эффективности [2]. Актуальность разработки таких систем подтверждается растущим интересом к применению технологий искусственного интеллекта в управлении бизнес-процессами [3].

Связанные работы

Исследования в области цифровых двойников охватывают различные аспекты их применения. В промышленности ЦД используются для оптимизации производственных процессов и прогнозирования технического состояния оборудования [4]. В сфере управления бизнес-процессами данное направление только начинает развиваться, однако уже демонстрирует значительный потенциал [5].

Концептуальные основы построения цифровых двойников бизнес-процессов описаны в работах Гривса [6], где предложена трехкомпонентная модель, включающая физический объект, его виртуальное представление и связь между ними. Дальнейшее развитие эта концепция получила в исследованиях Тао с соавторами [7], где акцент был сделан на использовании больших данных для создания высокоточных моделей.

В контексте процессного управления следует отметить работы Масаева с соавторами [8], посвященные применению цифровых двойников в управлении компетенциями персонала. Авторы демонстрируют возможность использования ЦД для моделирования профессионального развития и прогнозирования эффективности трудовой деятельности.

Автор данной работы также обращался к теме методов прогнозирования показателей бизнес-процессов в работах [9, 10], в которых были предложены нейросетевые модели для предсказания ключевых показателей эффективности на основе исторических данных. Эти исследования показали возможность достижения высокой точности прогнозов с коэффициентом детерминации более 0,7 для большинства моделей.

Вместе с тем, анализ литературы показывает недостаточную разработанность методов интеграции цифровых двойников в системы управления бизнес-процессами, что определяет необходимость дальнейших исследований в данном направлении.

Постановка задачи и экспериментальные материалы

Объектом анализа и прогнозирования в данной работе является дискретный (содержащий ограниченное счетное количество состояний – стадий жизненного цикла продукта/услуги) процесс, описываемый типовыми сценариями, выполняющимися на наборе операций набором организационных и материальных ресурсов.

В данной статье в качестве исследуемого бизнес-процесса выступает учебный процесс организации высшего образования. В качестве этапа процесса будет рассматриваться один семестр учебного плана. Сценарий выполнения стадии бизнес-процесса описывается рабочим учебным планом на семестр.

Сценарии применяются к уникальным экземплярам – партиям продукции, клиентам и т.п. В случае университета таким экземпляром является обучающийся.

В роли показателей (метрик) результата процесса выступают показатели продукта (услуги), являющейся выходом каждой из стадий жизненного цикла. В случае с университетом в роли таких метрик выступают результаты промежуточных аттестаций в течении семестра и отметки, выставляемые студентам по предметам в конце семестра.

Следует отметить, что такой подход к моделированию делает затруднительным для прогнозирования результатов аппарата прогноза временных рядов. Это обусловлено тем, что хотя показатели различных стадий характеризуют один и тот же процесс, но связаны с различными результатами, то есть набор метрик на разных стадиях будет различным и даже размерность их не обязана совпадать от стадии к стадии.

В качестве экспериментальных данных (цифровой тени процесса) исполь-

зовались данные об истории успеваемости студентов СибГУ им. М.Ф. Решетнева. Данные извлекались из реестров корпоративной информационной системы 1С:Университет Проф:

- Аттестация (с 2017 г, 1.2 млн записей) – сведения об оценках.
- Аттестация МРТО (с 2017 г, 1.2 млн записей) – сведения о контрольных точках в семестре
- Назначенные расчеты – сведения о назначенных стипендиях
- Достижения абитуриентов (с 2020 г., 85 тыс. записей) – сведения об абитуриентах при поступлении, включая сведения о баллах ЕГЭ.

Методы решения задачи

Архитектура цифрового двойника

Разработанный цифровой двойник бизнес-процессов реализует концепцию, предложенную в [11], и включает следующие компоненты:

1. Модуль интеграции с источниками данных (цифровая тень)
2. Нейросетевой прогностический блок
3. Модуль анализа и визуализации результатов
4. Систему генерации корректирующих воздействий

Структура базы измерений показателей процесса, включает следующие значения:

- Дату измерения
- Ответственное подразделение
- Вариант процесса
- Экземпляр процесса (идентифицируемый уникальным номером)
- Стадию процесса
- Показатель процесса
- Единицу измерения
- Значение показателя
- Ответственное за показатель подразделение
- Ответственного за показатель сотрудника

Постановка задачи нейросетевого прогнозирования

Задача прогнозирования формулируется как регрессионная проблема многомерного временного ряда. Для каждой стадии процесса t и каждого показателя p_i строится отдельная модель прогнозирования:

$$\hat{y}_{t,p_i} = f(X_{t-1}, \theta_{p_i})$$

где:

- $\hat{y}_{t,p_i}$ – прогнозируемое значение показателя p_i на стадии t
- X_{t-1} – вектор признаков, включающий атрибуты экземпляра процесса и значения показателей на предыдущих стадиях
- θ_{p_i} – параметры модели для показателя p_i
- f – нейросетевая функция прогнозирования

Архитектура нейронной сети

Для решения задачи прогнозирования применяется полносвязная нейронная сеть следующей структуры:

АЛГОРИТМ Создание_нейросетевой_модели

ВХОД: размерность_признаков – целое число

ВЫХОД: модель – объект нейронной сети

ПЕРЕМЕННЫЕ :

входной_слой: слой нейронной сети

скрытый_слой_1: слой нейронной сети

скрытый_слой_2: слой нейронной сети

выходной_слой: слой нейронной сети

НАЧАЛО

Входной слой

входной_слой =

Слой_Входа (формат=(размерность_признаков,))

Первый скрытый слой: 128 нейронов с активацией

```

TanH
    скрытый_слой_1 = Полносвязный_Слой(нейроны=128, ак-
тивация='tanh') (входной_слой)

    # Второй скрытый слой: 128 нейронов с активацией
TanH
    скрытый_слой_2 = Полносвязный_Слой(нейроны=128, ак-
тивация='tanh') (скрытый_слой_1)

    # Выходной слой: 1 нейрон с линейной активацией
    выходной_слой = Полносвязный_Слой(нейроны=1, актива-
ция='линейная') (скрытый_слой_2)

    # Создание модели
    модель = Модель(входы=входной_слой, выхо-
ды=выходной_слой)

    # Компиляция модели с оптимизатором Adam и функцией
потерь MSE
    модель.компилировать(
        оптимизатор='Adam',
        функция_ошибки='среднеквадратичная_ошибка',
        метрики=['средняя_абсолютная_ошибка']
    )

    ВЕРНУТЬ модель
КОНЕЦ АЛГОРИТМА

```

Рис. 1. Архитектура нейронной сети предсказания показателей.

Процесс обучения моделей

Набор моделей обучается отдельно для каждого подварианта процесса, исходя из предположения, что в этих рамках набор всех показателей экземпляра процесса на всех стадиях и для всех экземпляров остается стабильным.

Обучение нейросетевых моделей в составе цифрового двойника осуществляется по следующему алгоритму:

АЛГОРИТМ Обучение_моделей_прогнозирования

ПЕРЕМЕННЫЕ :

атрибуты_экземпляров: МАССИВ
измерения_показателей: МАССИВ
модели: СЛОВАРЬ
нормализаторы: СЛОВАРЬ
параметры_обучения: СТРУКТУРА

НАЧАЛО

ДЛЯ каждой стадии_процесса от 1 ДО максимальной_стадии

ЕСЛИ стадия_процесса = 1 **ТО**

признаки = извлечь_атрибуты(атрибуты_экземпляров)

целевые_переменные = из-

влечь_показатели(измерения_показателей, стадия_процесса)

ИНАЧЕ

признаки = объединить (

извлечь_атрибуты(атрибуты_экземпляров) ,

извлечь_показатели(измерения_показателей, стадия_процесса-

1)

)

целевые_переменные = из-

влечь_показатели(измерения_показателей, стадия_процесса)

КОНЕЦ ЕСЛИ

Нормализация признаков

нормализатор = Создать_StandardScaler()

нормализованные_признаки = нормализа-

тор.обучить_и_применить(признаки)

сохранить_нормализатор(нормализатор, стадия_процесса)

```

ДЛЯ каждого показателя_процесса в стадии_процесса
    # Создание модели нейронной сети
    модель = Создани_
ние_нейросетевой_модели(размерность(нормализованные_признаки) )

    # Обучение модели
    история = модель.обучить (
        нормализованные_признаки,
        целевые_переменные[показатель_процесса],
        эпохи=параметры_обучения.эпохи,
        размер_пакета=параметры_обучения.размер_пакета,
        validation_split=параметры_обучения.доля_валидации,
        verbose=0
    )

    # Сохранение обученной модели
    сохранить_модель(модель, стадия_процесса, показате_
тель_процесса)
КОНЕЦ ДЛЯ
КОНЕЦ ДЛЯ
КОНЕЦ АЛГОРИТМА

```

Рис. 2. Алгоритм обучения нейросетевых моделей прогноза
показателей.

Процесс прогнозирования показателей

Для прогнозирования показателей используется следующий алгоритм:

АЛГОРИТМ Прогнозирование_показателей

ПЕРЕМЕННЫЕ :

экземпляр_процесса: **СТРУКТУРА**

модели: **СЛОВАРЬ**

нормализаторы: **СЛОВАРЬ**

прогнозы: **СЛОВАРЬ**

НАЧАЛО

ДЛЯ каждой стадии_процесса от 1 ДО максимальной_стадии

ЕСЛИ стадия_процесса = 1 **ТО**

признаки = извлечь_атрибуты(экземпляр_процесса)

ИНАЧЕ

предыдущие_показатели = получить_прогнозы(прогнозы,
стадия_процесса-1)

признаки = объединить(
извлечь_атрибуты(экземпляр_процесса) ,
предыдущие_показатели
)

КОНЕЦ ЕСЛИ

Применение нормализации

нормализованные_признаки = нормализаторы[стадия_процесса].применить(признаки)

ДЛЯ каждого показателя_процесса на стадии

Получение прогноза от нейросетевой модели

прогноз = модели[стадия_процесса][показатель_процесса].предсказать(
нормализованные_признаки
)

Сохранение прогноза

сохранить_прогноз(прогнозы, стадия_процесса, показатель_процесса, прогноз)

КОНЕЦ ДЛЯ

КОНЕЦ ДЛЯ

ВЕРНУТЬ прогнозы

КОНЕЦ АЛГОРИТМА

Рис. 3. Алгоритм формирования прогноза показателей.

Результаты

В качестве экспериментального объекта использовалась история процесса обучения студентов в Институте информатики и телекоммуникаций (ИИТК) СибГУ им. М.Ф. Решетнева по направлению 09.03.04 «Программная инженерия» по дневной форме обучения.

Рассмотрим результаты тестирования моделей предсказания оценок (мы, как было сказано выше, рассматриваем их как показатели экземпляра процесса) за два произвольно выбранных этапа процесса – на примере начала процесса (1 семестр) и на примере предзаключительного этапа (7 семестра).

Табл. 1. Проверка предсказательной способности модели на 1 семестре

Показатель (оценка по предмету)	MAE	R2
Алгебра и аналитическая геометрия	0,696433	0,538682
Введение в дискретную математику	0,008534	0
Введение в программную инженерию	0,011355	0
Инженерная и компьютерная графика	0,738957	0,499851
Иностранный язык	0,39324	0,260023
Информатика	0,014141	0
Информатика и программирование	1,40908	0,509503
Информационные технологии в цифровой экономике	0,533423	0,483921
История	0,015469	0
Математический анализ	0,645721	0,493751
Организация и технология документационного обеспечения программных продуктов	0,013659	0
Основы программной инженерии	0,591636	0,455997
Основы российской государственности	0,189612	0,955802
Профессионально-прикладная физическая культура	0,016261	0
Русский язык и культура речи	0,323409	0,414398

Физическая культура и спорт	0,434535	0,26301
Языки программирования	0,668767	0,481772

Табл. 2. Проверка предсказательной способности модели на 7 семестре

Показатель (оценка по предмету)	MAE	R2
Защита информации	0,007458	0
Инструментальные средства проектирования и разработки ПО	0,003207	0
Компьютерные сети и телекоммуникации	0,356395	0,729667
Конструирование программного обеспечения	0,00589	0
Математические основы искусственного интеллекта	0,260639	0,963447
Модели процессов и систем	0,036448	0
Надежность информационных систем	0,186763	0,969732
Нейрокомпьютерные системы	0,409316	0,84747
Организация проектной деятельности ИТ-специалиста в области программной инженерии	0,149877	0,983698
Основы инженерной психологии	0,356401	0,926476
Основы научно-исследовательской деятельности	0,220054	0,957552
Проблемно-ориентированные мультилингвистические технологии	0,040258	0
Программирование мехатронных систем	0,167436	0,9839
Программное обеспечение мобильных и встраиваемых систем	0,437811	0,858377
Разработка мобильных приложений	0,3665	0,922056
Разработка серверных Web- приложений	0,200995	0,981959
Рефакторинг баз данных: эволюционное проектирование	0,054473	0
Сетевое администрирование и защита информации	0,002005	0
Синхронный и технический перевод в сфере ИТ	0,07755	0

Теория принятия решений	0,094296	0
Тестирование и сопровождение ПО	0,003301	0
Тестирование программного обеспечения	0,302009	0,76192
Технологии разработки интеллектуальных систем	0,223913	0,958362
Управление программными проектами	0,307168	0,950532
Экономика	0,346387	0,93826
Экономика отрасли информационных технологий	0,305727	0,959183

Обсуждение

Результаты исследования демонстрируют эффективность предложенного подхода к построению цифрового двойника бизнес-процессов. Полученные значения точности прогнозирования соответствуют мировому уровню разработок в данной области [12].

«Просадка» значений показателей меры детерминации для ряда оценок (см. таблицы 1, 2) при очень высокой точности предсказания (средний модуль ошибки на уровне $10^{-2} - 10^{-3}$) возникает за счет нередкого в вузовской среде «феномена» - проставка оценки «ровными рядами» – всем студентам одинаково, нейросеть воспроизводит значения, но выходные значения не имеют вариативности, позволяющей подсчитать метрику R2.

Основными преимуществами разработанного решения являются:

- Высокая точность прогнозирования ключевых показателей эффективности
- Возможность генерации корректирующих воздействий
- Адаптивность к различным процессным конфигурациям
- Интеграция с существующими системами управления бизнес-процессами

Выбранная архитектура нейронной сети с двумя скрытыми слоями по 128 нейронов каждая показала хорошую сбалансированность между точностью прогнозирования и вычислительной эффективностью. Использование функции активации $\tanh$ в скрытых слоях обеспечило нелинейность модели при сохранении

вычислительной эффективности, а линейная функция активации на выходном слое позволила получить прогнозы в непрерывном диапазоне значений.

Выводы

Разработанная модель цифрового двойника бизнес-процессов доказала свою эффективность в прогнозировании ключевых показателей эффективности. Применение нейросетевых методов регрессии позволило достичь высокой точности прогнозов для различных стадий бизнес-процесса. Перспективы дальнейших исследований включают интеграцию с системами управления бизнес-процессами и расширение функционала для поддержки принятия управленческих решений в организациях.

С точки зрения развития архитектуры нейросетевого решения рассматривается применение графовых нейронных сетей для прогнозирования динамики системы по стадиям процесса.

Список литературы

1. Grieves M. Digital twin: manufacturing excellence through virtual factory replication // White Paper. 2015. 7 p.
2. Kritzinger W., Karner M., Traar G. et al. Digital Twin in manufacturing: A categorical literature review and classification // IFAC-PapersOnLine. 2018. Vol. 51. No. 11. P. 1016-1022. DOI: 10.1016/j.ifacol.2018.08.474
3. Tao F., Zhang M., Liu Y. et al. Digital twin driven prognostics and health management for complex equipment // CIRP Annals. 2018. Vol. 67. No. 1. P. 169-172. DOI: 10.1016/j.cirp.2018.04.055
4. Masaev S.N., Minkin A.N., Troyak E.Y. et al. Digital twin in advanced training of engineering specialists // Journal of Physics: Conference Series. 2021. Vol. 1889. No. 2. P. 022045. DOI: 10.1088/1742-6596/1889/2/022045
5. Grieves M. Virtually intelligent product systems: digital and physical twins // Complex Systems Engineering: Theory and Practice. 2019. P. 175-200. DOI: 10.2514/5.9781624105654.0175.0200

6. Tao F., Zhang H., Liu A. et al. Digital twin in industry: State-of-the-art // IEEE Transactions on Industrial Informatics. 2018. Vol. 15. No. 4. P. 2405-2415. DOI: 10.1109/TII.2018.2873186
7. Masaev S.N., Dorrer G.A., Minkin A.N. et al. Assessment of the application of the Universal Competencies // Journal of Physics: Conference Series. 2020. Vol. 1691. No. 1. P. 012020. DOI: 10.1088/1742-6596/1691/1/012020
8. Dorrer M.G., A neural network regression model for predicting student learning success based on prior achievements // ITM Web of Conferences. 2025. Vol. 72. P. 05007. DOI: 10.1051/itmconf/20257205007
9. Dorrer M.G., Implementation of the digital twin of business processes on the ELMA BPMS platform // AIP Conference Proceedings. 2022. Vol. 2647. No. 1. P. 040088. DOI: 10.1063/5.0104164
10. Dorrer M.G., The digital twin of the business process model // Journal of Physics: Conference Series. 2020. Vol. 1679. No. 3. P. 032096. DOI: 10.1088/1742-6596/1679/3/032096
11. Uhlemann T.H.J., Lehmann C., Steinhilper R. The digital twin: Realizing the cyber-physical production system for Industry 4.0 // Procedia CIRP. 2017. Vol. 61. P. 335-340. DOI: 10.1016/j.procir.2016.11.152
12. Negri E., Fumagalli L., Macchi M. A Review of the Roles of Digital Twin in CPS-based Production Systems // Procedia Manufacturing. 2017. Vol. 11. P. 939-948. DOI: 10.1016/j.promfg.2017.07.198

КЛАСТЕРИЗАЦИЯ ВОДОСБОРОВ ЧЕТЫРЕХ РЕК КРАСНОЯРСКОГО КРАЯ НА ОСНОВЕ ДЗЗ

М.Г. Ерунова, О.Э. Якубайлик, А.А. Кадочников, М.Ю. Сенашова

Институт вычислительного моделирования СО РАН, msen@icm.krasn.ru

1. Введение

Любой природный объект, имеющий экологическую или экономическую ценность, имеет сложное поведение и описывается большим набором параметров. Учет и анализ всех имеющихся параметров часто бывает избыточным и затрудняет построение адекватной модели. Выбор сокращенного набора параметров, который, тем не менее, адекватно описывает природный объект, требует экспертной оценки биологов, экологов, экономистов, специалистов по математическому моделированию и лиц, участвующих в процессах принятия решений. Были предприняты многочисленные попытки поиска некоторых обобщенных, малоразмерных данных, адекватно описывающих природные объекты (Li et al., 2019; Chen et al., 2018; Indrayani et al., 2017). Однако универсального решения пока не найдено (Wu et al., 2017). На практике показывает высокую эффективность подход, основанный на многофакторном анализе данных ДЗЗ (см., например, Ikhumhen et al. (2020)). В данной работе мы опираемся на этот подход. Для анализа и обработки данных ДЗЗ требуется использование специализированных инструментов для исследования, таких как геоинформационные системы (ГИС). Эффективность этой методологии хорошо подтверждена (см., например, Erunova et al. (2006); Ikhumhen et al. (2020); Lu et al. (2012); Store and Jokimaäki (2003) и другие).

В настоящее время данные о географических и погодных параметрах можно легко получить со спутников. Дистанционное зондирование Земли (ДЗЗ) является современной, высокоэффективной, постоянно развивающейся технологией. Очень высокая детализация данных как в пространстве, так и во времени, делает ДЗЗ особенно актуальным.

1.1. Цель статьи

Кластеризацию нельзя выполнить без определения элементарных объектов. Актуальной проблемой является определение наименьшего объекта, отвечающего всем необходимым условиям.

Мы считаем, что при выборе элементарного объекта большую роль играет морфометрия. Действительно, рельеф во многом определяет направление течения воды, тем самым влияя на экологические свойства участка. В качестве альтернативы морфометрии можно рассматривать пиксель данных, предоставляемый различными платформами геоданных (Sardooi et al., 2019). Такой подход кажется несколько спорным. Формально определенный пиксель, полученный из записей дистанционного зондирования, может включать в себя географические объекты с разными свойствами, что может со-

здать многочисленные проблемы при дальнейшем анализе. Речной бассейн представляется более подходящим кандидатом на элементарный объект при моделировании и изучении вопросов землепользования и управления (Mendoza et al., 2011). Этот подход относительно эффективен для анализа сельскохозяйственных территорий. Цифровая модель здесь основана на следующих параметрах: уклон, экспозиция, кривизна поверхности земли, определение зоны видимости и т. д. (Egunova and Yakubailik, 2020).

Пространственная неоднородность создает еще одну проблему: различные участки различаются по климатическим условиям, почве, рельефу, геологическому субстрату, насаждениям и фауне, не говоря о физическом местоположении участка. Эти особенности обычно описываются в терминах зональной сети. Сельское хозяйство и другие виды природопользования также вносят свой вклад в проблему.

Была рассмотрена территория, расположенная в Красноярском крае и включающая водосборы четырех средних по масштабу рек (река Кан, река Мана, река Оя и река Туба).

На данной территории были выделены водосборы 4-х уровней. Водосбором первого уровня мы считаем бассейны рек, водосбором второго уровня бассейны их притоков и т.д. Для каждого водосбора 4-го уровня был зафиксирован следующий набор параметров: высота над уровнем моря, уклон, преобладающая растительность, ориентация относительно сторон света, TWI, LS, вид почвы, суммарное количество осадков за год, сумма положительных температур за год, сумма отрицательных температур за год. Данные по осадкам и температуре были взяты за 5 лет (2019-2024 годы). Основная цель статьи – выяснить, группируются ли водосборы 4-го уровня на основе этих параметров.

2. Материалы и методы

2.1. Район исследования

Для исследования были взяты четыре водных бассейна Восточной Сибири. Это бассейны рек Красноярского края, а именно реки Кан, Мана, Туба и Оя, общей площадью 89 103 км², охватывающие 6 долгот (91 – 97 в. д.) и 4 широты (52 – 56 с. ш.). Эти четыре водных бассейна расположены в центральной части Красноярского края и включают в себя различные наземные экосистемные комплексы. Полное определение таких комплексов можно найти в (Potter et al., 1993; Chapin III et al., 2011).

В этом районе есть три типа рельефа: холмистая местность с высотой от 200 до 500 м, низкие горы (от 500 до 1 000 м) и среднегорья с высотой от 1 000 до 2 000 м. Средний уровень осадков (за 20-летний период наблюдений) составляет 650 мм в год. Климат также довольно разнообразен, значения единиц степени роста (GDU) (см. ниже), наблюдаемые в 2019 году, варьировались от 650 до 2 900 единиц. Исследуемая территория демонстрирует большое разнообразие природных и географических объектов. Среди них степь, лесостепь, тайга, смешанные и широколиственные леса. Примерно половину площади занимают сельскохозяйственные угодья, расположенные в ос-

новном в долинах.

Другая часть площади покрыта горной тайгой и тундрой Саян с крутыми склонами и пересеченным рельефом. Значительная часть площади имеет высокую экономическую ценность для Красноярского края.

2.2. Цифровая модель водоразделов Красноярского края

Для нашего исследования мы разработали иерархическую модель классификации водосборов для региона, которая состоит из четырех уровней. Для этого мы использовали ГИС Whitebox GAT, QGIS (с модулями GRASS) и программное обеспечение ArcGIS (Ерунова и Якубайлик, 2020). Исходные данные, лежащие в основе модели:

- MERIT Hydrologically Adjusted Elevations DEM с пространственным разрешением 90 м на экваторе, полученные из последних данных о высотных отметках (MERIT DEM) (Yamazaki et al., 2019);
- был разработан векторный слой геосистемы речных бассейнов с использованием оригинального подхода на основе рельефа MERIT DEM с применением WhiteboxGAT (Lindsay, 2016) с последующей обработкой данных программным пакетом GRASS в QGIS;
- гидрографическая сеть, перенесенная с российских топографических карт масштабов 1:10 000 000, 1:2 500 000 и 1:1 000 000 в векторных форматах.

Разработана четырехуровневая схема классификации водоразделов притоков рек с учетом детализации векторных слоев гидрографической сети разных масштабов. Всего выделено 1105 водоразделов низшего уровня, со средней площадью примерно 0.008 км².

2.3. Источник данных: температура, осадки, индексы растительности

В Мире существует несколько глобальных моделей прогноза погоды и осадков, которые охватывают весь земной шар и различаются между собой по временному и пространственному разрешению. В работе использовались данные модели Global Forecast System (GFS), разработанной американской метеорологической службой (Hewage et al., 2021). GFS – самая известная глобальная модель погоды, которая обновляется четыре раза в сутки. С помощью этой модели были получены данные о температуре поверхности. Дополнительно были получены данные об осадках с помощью глобальной модели Global Precipitation Measurement (GPM). GPM – международный проект, помогающий исследователям в изучении глобального климата и улучшении прогнозирования экстремальных погодных явлений (Skofronick-Jackson et al., 2017). Более пяти лет назад в Институте вычислительного моделирования СО РАН (ИВМ СО РАН) был сформирован архив данных проектов GFS (на территорию России) и GPM (глобальное покрытие), ежедневно выполняется загрузка новых данных (Kadochnikov, 2021; Токарев,

2023). Для извлечения данных об осадках использовался набор данных «IMERG Final Run», который получен с использованием большего количества информации и является более точным по сравнению с наборами «IMERG Early Run» и «IMERG Late Run» (Rajani et al., 2022). Данные модели GFS имеют пространственное разрешение 0,25 градуса, данные модели GPM – 0,1 градуса.

Для анализа данных по водосборным территориям разработан набор программ для расчета средневзвешенных значений по каждой территории по данным глобальных моделей и данным спутниковой съемки. При расчете учитываются все пиксели, попавшие в область с учетом площади, возникшей при пересечении пикселей растра с границей области. Территория задается с помощью векторного файла в формате ESRI Shape, содержащего один или более площадных объектов. Программа выполняет сканирование каталога с данными глобальных моделей GFS и GPM, а также с данными спутниковой съемки с аппаратов Terra и Aqua с прибором MODIS. Данные представлены в растровом формате GeoTIFF (GPM и MODIS) и GRIB2 (GFS). В результате работы программы формируется выборка пикселей растровых файлов и рассчитывается средневзвешенное значение для выбранных полигонов. Каждое рассчитанное значение по выбранному показателю записывается в базу данных. В дальнейшем результат может быть выгружен из базы данных в табличном виде в формате CSV. Полученный результат содержит информацию об осадках, температуре поверхности и других показателях с 2019 по 2024 годы.

Программы обработки файлов и экспорта результата реализованы на языке Python 3 с использованием библиотек GDAL и OGR и языке сценариев Bash. Для хранения данных применяется СУБД PostgreSQL с модулем расширения PostGIS.

2.4. Методы кластерного анализа

Итак, в конечном итоге мы хотим идентифицировать кластеры (если таковые имеются) в этом пространстве и проверить, включают ли эти кластеры водоразделы с определенными свойствами или нет.

Для кластеризации данных (то есть водосборов в 10-мерном пространстве) мы использовали метод К-средних (Fukunaga, 2013), метод главных компонент и метод упругой карты. Методы К-средних и главных компонент хорошо известны и изучены. Мы не будем останавливаться на сути этих методов. Метод упругой карты, реализованный в свободно распространяемом программном обеспечении VidaExpert (Gorban и Зиновьев, 2015; Akinduko и Gorban, 2014; Mirkes и др., 2013), известен не так широко. Этот метод позволяет уменьшить размерность данных, визуализировать их и получить кластеризацию, если таковая имеется. Основная идея метода состоит в аппроксимации многомерных данных многообразием низкой размерности; для этого мы использовали двумерное многообразие (в нашем случае квадрат). Метод состоит из пяти шагов.

1. По набору данных вычисляются первая и вторая главные компоненты, по ним

строится регулярная плоскость.

2. Далее, все точки данных проецируются на плоскость, определяемую первыми двумя главными компонентами, и определяется минимальный квадрат, покрывающий проекции. Этот минимальный квадрат будет использоваться для аппроксимации данных.

3. Минимальный квадрат должен быть покрыт решеткой. Мы использовали программное обеспечение VidaExpert, обеспечивающее три типа покрытия: 12×12 ячеек (жесткая карта), 16×16 ячеек (мягкая карта) и 25×25 ячеек (подробная карта). Как только покрытие выбрано, каждая точка данных связывается с узлом решетки, ближайшим к проекции точки, математической пружиной. Пружина имеет бесконечную линейную растяжимость.

4. Затем изначально жесткий квадрат заменяется на упругую мембрану. Система освобождается для достижения минимума полной энергии деформации посредством деформации мембраны и растяжения пружин. Мембрана должна быть линейно-кусочной и однородной. Это означает, что деформация, обсуждаемая ниже, дает негладкое многообразие, состоящее из набора деформированных четырехугольников, так что они соединены своими краями, и каждый из них по-прежнему является плоскостью. Каждый четырехугольник может быть аффинно преобразован; однако мембрана может изгибаться только на краях четырехугольников. Ни склеивание, ни разрыв не допускаются: топология мембраны должна сохраняться.

5. Система, состоящая из упругой мембраны и набора математических пружин, должна быть освобождена для достижения минимума полной энергии деформации. Эта конфигурация мембраны дает упругую карту, которая будет использоваться для дальнейшего анализа. После деформации каждое изображение точки данных на упругой карте должно быть переопределено. Для этого должна быть найдена ортогональная проекция (то есть точка на растянутой поверхности, ближайшая к исходной).

После этого упругая карта готова к использованию для дальнейшего анализа и кластеризации данных. Чтобы выявить кластеры (если таковые имеются), нужно отрезать все пружины, тем самым позволяя карте вернуться обратно в плоскость (это так называемое представление во внутренних координатах). Обратное преобразование деформированной карты делает некоторые точки ближе, другие - более удаленными, в соответствии с деформацией, обеспечиваемой коллективным воздействием всех пружин и мембраны.

3. Результаты

Мы проанализировали кластеры, образованные 1105 бассейнами в 10-мерном метрическом пространстве параметров, описанных в подпункте 1.1. Начнем анализ кластерной структуры набора водосборов с метода главных компонент. Для набора параметров были вычислены корреляции. Было обнаружено, что данный набор включает

сильно скоррелированные параметры. Высота над уровнем моря имеет коэффициент корреляции с уклоном равный 0,88, с TWI -0,76, с LS 0,83, с суммой отрицательных температур от -0,79 до -0,86, с суммой положительных температур от -0,89 до -0,94 в зависимости от года. Уклон имеет коэффициент корреляции с TWI -0,84, с LS 0,95, с суммой отрицательных температур от -0,75 до -0,83, с суммой положительных температур от -0,82 до -0,87 в зависимости от года. TWI имеет коэффициент корреляции с суммой положительных температур от 0,89 до 0,94 в зависимости от года. LS имеет коэффициент корреляции с суммой отрицательных температур от -0,73 до -0,8, с суммой положительных температур от -0,8 до -0,85 в зависимости от года. Сумма отрицательных температур имеет коэффициент корреляции с суммой положительных температур от 0,75 до 0,88. Сильно скоррелированные параметры были удалены из рассмотрения, в результате набор параметров сократился до растительности, ориентации по сторонам света, виду почвы, осадков и суммы отрицательных температур.




Рис. 1. Кластеризация водосборов в пространстве первых трех главных компонент для параметров без погодных данных а) и для параметров с учетом осадков и температуры соответственно с 2019 б) по 2024 год ж).

Мы рассмотрели классификацию водосборов с помощью К-средних для $2 \leq k \leq 8$. Никакой стабильной (или даже частично стабильной) классификации с помощью К-средних обнаружено не было, даже для $K = 2$. Этот факт кажется относи-

тельно естественным: конфигурация данных допускает различные классификации с К-средними, так что они дополняют друг друга в течение серии запусков метода. Рост числа классов в методе К-средних еще больше ухудшает классификацию.

Далее мы использовали метод главных компонент. Поскольку погодные данные (температура и осадки) меняются в зависимости от года, мы рассмотрим дополнительно, как кластеризуются параметры, не зависящие от погоды. В этот набор были включены высота над уровнем моря, растительность, ориентация по сторонам света и вид почвы. Высота над уровнем моря была включена в набор, чтобы не потерять информацию. В наборах с погодными данными эта информация косвенно учитывается в параметре суммарная отрицательная температура, так как они сильно скореллированы. Для набора без погодных данных вклад параметров в главные компоненты выглядит следующим образом: максимальные коэффициенты для первой главной компоненты имеют высота над уровнем моря (0,68) и вид почвы (-0,64), для второй главной компоненты растительность (0,91), для третьей главной компоненты ориентация по сторонам света (-0,89). Суммарная дисперсия для первых трех главных компонент составляет 0,89. Для полных наборов данных вклад параметров в главные компоненты меняется от года к году. Но для всех лет в первой главной компоненте присутствует сумма отрицательных температур, а во второй ориентация по сторонам света.

Для всех наборов данных по годам и без учета погодных данных было получено распределение точек на два кластера. Состав кластеров совпадает для всех наборов. Вид кластеров в пространстве первых трех главных компонент показан на рис. 1.




Рис. 2. Деление на подкластеры исходных кластеров для метода упругой карты. Точки окрашены в цвета исходных кластеров а) и окрашены как самостоятельные кластеры б).

Основной параметр, влияющий на разделение водосборов по кластерам – ориентация по сторонам света. Большая часть водосборов кластера 1 ориентирована на восток, а кластера 2 на запад. Высота над уровнем моря и уклон в среднем меньше, а

суммарная положительная температура в среднем выше в кластере 1. Виды почвы в кластере 1 преимущественно дерново-подзолистые, дерново-таежные кислые и серые лесные. В кластере 2 кроме этих почв значительную часть составляют подбурные таежные. В кластере 1 преобладающая растительность смешанный лес и земли сельскохозяйственного назначения. В кластере 2 кроме этих видов растительности большое количество лиственного и темнохвойного леса.




Рис .3. Дополнительная кластеризация с помощью упругой карты с учетом погодных данных с 2019 а) по 2024 годы е).

Далее полученная кластеризация была использована в методе упругой карты. Использовалась мягкая 16×16 упругая карта. Было обнаружено, что точки, относящиеся к одному кластеру, делятся на подкластеры. Пример показан на рис. 2а). Этот набор параметров не включает погодные данные. При разделении на 4 кластера из кластера 1 выделился кластер 3 с меньшими высотами над уровнем моря (среднее значение для этого кластера 389, для кластера 1 среднее значение 723), более высокой суммарной отрицательной температурой (для кластера 3 среднее значение -1771,86, для кластера 1 среднее значение -2081,3) и ориентацией водосборов из этого кластера на запад. Из кластера 2 выделился кластер 4. В этот кластер попали водосборы с меньшей высотой над уровнем моря (для кластера 2 среднее значение 977,75, для кластера 4 среднее значение 675,12), преобладают лиственные леса и сельскохозяйственные угодья (в кластере 2 преобладают смешанные леса и не лес), более высокой суммарной отрицательной

температурой (для кластера 4 среднее значение -188,01, для кластера 2 среднее значение -2450,72) и ориентацией водосборов из этого кластера на восток.




Рис. 4. Распределение кластеров на местности. С учетом погодных данных с 2019 а) по 2024 год е) и без учета погодных данных ж).

Для наборов параметров, включающих погодные данные, на 4 кластера раздели-

лись данные за 2024 год, данные за все остальные годы разделились на 3 кластера. На рис. 3 показана получившаяся кластеризация по годам с учетом погодных данных. Для данных за 2024 год состав кластеров схож с составом кластеров без погодных данных, но количество водосборов в кластерах 3 и 4 меньше. Для остальных лет в третий кластер попадают водосборы из кластера 1 с ориентацией на запад и более высокой суммарной отрицательной температурой.

Распределение кластеров на местности показано на рис. 4.

4. Обсуждение

Как видно из полученных результатов, использование водосборов низких уровней в качестве элементарного объекта позволяет получить достаточно устойчивую кластеризацию.

Линейный метод главных компонент дает устойчивую кластеризацию на два кластера как для набора параметров с учетом погодных данных, так и без них. Нелинейный метод упругой карты позволяет детализировать данные и получить дополнительные кластеры, которые содержат водосборы с характеристиками, выделяющими их из основного кластера. Погодные условия оказывают влияние на кластеризацию. Так более жаркое лето и более мягкая зима 2024 года привели к образованию 4 кластеров, в отличие от предыдущих лет с очень схожим разделением на кластеры.

Метод упругой карты позволяет выделить кластеры более низкого уровня в уже описанных выше кластерах, как видно из рис. 3. Это позволяет построить иерархию кластеров, где кластеры более низкого уровня будут включать объекты более схожие по свойствам. Однако это не является целью данной работы.

5. Заключение

Здесь мы представляем новый подход к анализу земельных участков с точки зрения землепользования и природных ресурсов с использованием как географических (водосбор, высота, уклон, почвы, растительность) так и погодных данных (температура и осадки).

Подход показал свою эффективность при идентификации участков земли с достаточно небольшой площадью и одинаковыми свойствами. Выбор водосборов низкого уровня в качестве элементарного объекта землепользования вполне оправдан. Достаточно небольшой набор параметров, описывающих эти земельные участки позволяет получать устойчивую кластеризацию как с учетом погодных данных, так и без них.

СПИСОК ЛИТЕРАТУРЫ

1. Ahmad, A., Khan, S.S., 2019. Survey of state-of-the-art mixed data clustering algorithms. *IEEE Access* 7, 31883–31902.
2. Ahmed, M., 2019. Data summarization: a survey. *Knowledge and Information Systems* 58, 249–273.

3. Akinduko, A.A., Gorban, A., 2014. Multiscale principal component analysis, in: *Journal of Physics: Conference Series*, IOP Publishing, p. 012081.
4. Ali, M., Alqahtani, A., Jones, M.W., Xie, X., 2019. Clustering and classification for time series data in visual analytics: A survey. *IEEE Access* 7, 181314–181338.
5. Chapin III, F.S., Matson, P.A., Vitousek, P., 2011. *Principles of terrestrial ecosystem ecology*. Springer Science & Business Media.
6. Chen, H., Zhang, H., Shen, S.h., Yu, W., Zou, C., 2009. Construction and validation of a new model for cropland soil moisture index based on MODIS data, in: *Remote Sensing and Modeling of Ecosystems for Sustainability VI*, International Society for Optics and Photonics. p. 745418.
7. Chen, W., Xie, X., Peng, J., Shahabi, H., Hong, H., Bui, D.T., Duan, Z., Li, S., Zhu, A.X., 2018. GIS-based landslide susceptibility evaluation using a novel hybrid integration approach of bivariate statistical based random forest method. *Catena* 164, 135–149.
8. Erunova, M., Yakubailik, O., 2020. Zoning of the territory on the basis of morphometric analysis of basin geosystems, in: *IOP Conference Series: Earth and Environmental Science*, IOP Publishing. p. 062039.
9. Erunova, M.G., Sadovsky, M.G., Gosteva, A.A., 2006. GIS-aided simulation of spatially distributed environmental processes at “Stolby” state reservation. *Ecological Modelling* 195, 296–306.
10. Fukunaga, K., 2013. *Introduction to statistical pattern recognition*. Elsevier.
11. Gorban, A.N., Smirnova, E.V., Tyukina, T.A., 2009. General laws of adaptation to environmental factors: from ecological stress to financial crisis. *Mathematical Modelling of Natural Phenomena* 4, 1–53.
12. Gorban, A.N., Tyukina, T.A., Smirnova, E.V., Pokidysheva, L.I., 2016. Evolution of adaptation mechanisms: Adaptation energy, stress, and oscillating death. *Journal of theoretical biology* 405, 127–139.
13. Gorban, A.N., Zinovyev, A., 2015. Fast and user-friendly non-linear principal manifold learning by method of elastic maps, in: *2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, IEEE. pp. 1–9.
14. Guha, S., Govil, H., Gill, N., Dey, A., 2020. Analytical study on the relationship between land surface temperature and land use/land cover indices. *Annals of GIS* 26, 201–216.
15. Guo, K., Zhang, X., Kuai, X., Wu, Z., Chen, Y., Liu, Y., 2020. A spatial bayesian-network approach as a decision-making tool for ecological-risk prevention in land ecosystems. *Ecological Modelling* 419, 108929.
16. Haboudane, D., Miller, J.R., Pattey, E., Zarco-Tejada, P.J., Strachan, I.B., 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote sensing of environment* 90, 337–352.

17. Hewage, P., Trovati, M., Pereira, E. et al. Deep learning-based effective fine-grained weather forecasting model. *Pattern Anal Applic*, 2021. V. 24. P. 343–366. DOI: 10.1007/s10044-020-00898-1
18. Hou, A.Y., Kakar, R.K., Neeck, S., Azarbarzin, A.A., Kummerow, C.D., Kojima, M., Oki, R., Nakamura, K., Iguchi, T., 2014. The global precipitation measurement mission. *Bulletin of the American Meteorological Society* 95, 701–722.
19. Huete, A., 1988. A soil-adjusted vegetation index (SAVI). *Remote sensing of environment* 25, 295–309.
20. Ikhumhen, H.O., Li, T., Lu, S., Matomela, N., 2020. Assessment of a novel data driven habitat suitability ranking approach for *Larus relictus* specie using remote sensing and GIS. *Ecological Modelling* 432, 109221. URL: <https://www.sciencedirect.com/science/article/pii/S030438002030291X>, doi:<https://doi.org/10.1016/j.ecolmodel.2020.109221>.
21. Indrayani, P., Mitani, Y., Djamaluddin, I., Ikemi, H., 2017. A GIS based evaluation of land use changes and ecological connectivity index. *Journal of Geomatics and Planning* 4, 9–18.
22. Kadochnikov A.A. Development of data collection system for monitoring the atmospheric air state in Krasnoyarsk region. *Proceedings of the International conference “InterCarto. InterGIS” – 2021. Volume 27, Issue 2, P. 205-217. DOI: 10.35595/2414-9179-2021-2-27-205-217*
23. Kelkar, B.A., Rodd, S.F., 2019. Subspace clustering – a survey, in: *Data Management, Analytics and Innovation*. Springer, pp. 209–220.
24. Klein, I., Gessner, U., Kuenzer, C., 2012. Regional land cover mapping and change detection in Central Asia using MODIS time-series. *Applied Geography* 35, 219 – 234. URL: <http://www.sciencedirect.com/science/article/pii/S0143622812000720>, doi:<https://doi.org/10.1016/j.apgeog.2012.06.016>.
25. Krapez, J.C., Oliso, A., Coudert, B., 2009. Comparison of three methods based on the temperature-NDVI diagram for soil moisture characterization, in: *Remote Sensing for Agriculture, Ecosystems, and Hydrology XI*, International Society for Optics and Photonics. p. 74720Y.
26. Li, B., Wang, Z., Chai, J., Zhang, D., 2019. Index system to assess implementation of strategic land use plans in China. *Land Use Policy* 88, 104148.
27. Li, Z., Wu, W., Liu, X., Fath, B.D., Sun, H., Liu, X., 750 Xiao, X., Cao, J., 2017. Land use/cover change and regional climate change in an arid grassland ecosystem of Inner Mongolia, China. *Ecological Modelling* 353, 86–94. URL: <https://www.sciencedirect.com/science/article/pii/S0304380016302630>, doi:<https://doi.org/10.1016/j.ecolmodel.2016.07.019>. special Issue of China-Korea Joint Seminars on multi-disciplinary and multi-method approaches toward sustainable human and nature interactions.
28. Lindsay, J.B., 2016. Whitebox GAT: A case study in geomorphometric analysis. *Computers & Geosciences* 95, 75–84. URL: <https://doi.org/10.1016/j.cageo.2016.07.019>.

<http://www.sciencedirect.com/science/article/pii/S0098300416301820>,
doi:<https://doi.org/10.1016/j.cageo.2016.07.003>.

29. Lu, C.Y., Gu, W., Dai, A.H., Wei, H.Y., 2012. Assessing habitat suitability based on geographic information system (GIS) and fuzzy: A case study of *Schisandra sphenanthera* Rehd. et Wils. in Qinling Mountains, China. *Ecological Modelling* 242, 105–115. URL: <https://www.sciencedirect.com/science/article/pii/S0304380012002748>, doi:<https://doi.org/10.1016/j.ecolmodel.2012.06.002>.

30. Mahfuz, N.M., Yuso, M., Ahmad, Z., 2019. Review of single clustering methods. *IAES International Journal of Artificial Intelligence* 8, 221.

31. Mendoza, M.E., Granados, E.L., Geneletti, D., P´erez-Salicrup, D.R., Salinas, V., 2011. Analysing land cover and land use change processes at watershed level: a multitemporal study in the lake Cuitzeo watershed, Mexico (1975–2003). *Applied Geography* 31, 237–250.

32. Mirkes, E.M., Zinovyev, A., Gorban, A.N., 2013. Geometrical complexity of data approximators, in: *International Work-Conference on Artificial Neural Networks*, Springer. pp. 500–509.

33. Naouali, S., Salem, S.B., Chtourou, Z., 2020. Clustering categorical data: A survey. *International Journal of Information Technology & Decision Making*, 1–48.

34. Rajani K. Pradhan, Yannis Markonis, Mijael Rodrigo Vargas Godoy et al. Review of GPM IMERG performance: A global perspective. *Remote Sensing of Environment*, 2022. V. 268, P. 112754. DOI: 10.1016/j.rse.2021.112754.

35. Patil, P., Karthikeyan, A., 2020. A survey on k-means clustering for analyzing variation in data, in: *Inventive Communication and Computational Technologies*. Springer, pp. 317–323.

36. Potter, C.S., Randerson, J.T., Field, C.B., Matson, P.A., Vitousek, P.M., Mooney, H.A., Klooster, S.A., 1993. Terrestrial ecosystem production: a process model based on global satellite and surface data. *Global Biogeochemical Cycles* 7, 811–841.

37. Puzachenko, Y., Sandler, R., Krenke, A., Olchev, A., 2016. Assessing the thermodynamic variables of landscapes in the southwest part of east european plain in Russia using the MODIS multispectral band measurements. *Ecological Modelling* 319, 255–274. URL: <https://www.sciencedirect.com/science/article/pii/S0304380015003026>, doi:<https://doi.org/10.1016/j.ecolmodel.2015.06.046>. 40th Anniversary of Ecological Modelling Journal.

38. Qin, X., Ting, K.M., Zhu, Y., Lee, V.C., 2019. Nearest-neighbour induced isolation similarity and its impact on density-based clustering, in: *Proceedings of the AAAI Conference on Artificial Intelligence* 33, 805–812.

39. Intelligence, pp. 4755–4762.

40. Sardooi, E.R., Azareh, A., Choubin, B., Barkhori, S., Singh, V.P., Shamshirband, S., 2019. Applying the remotely sensed data to identify homogeneous regions of watersheds using a pixel-based classification approach. *Applied Geography* 111, 102071.

41. Shi, Z., Pun-Cheng, L.S., 2019. Spatiotemporal data clustering: a survey of methods. *ISPRS international journal of geo-information* 8, 112.
42. Silleos, N.G., Alexandridis, T.K., Gitas, I.Z., Perakis, K., 2006. Vegetation indices: advances made in biomass estimation and vegetation monitoring in the last 30 years. *Geocarto International* 21, 21–28.
43. Skofronick-Jackson G. et al. The Global Precipitation Measurement (GPM) mission for science and society. *Bulletin of the American Meteorological Society*, 2017. V. 98 (8). P. 1679-1695.
44. Store, R., Jokimäki, J., 2003. A GIS-based multi-scale approach to habitat suitability modeling. *Ecological Modelling* 169, 1–15. URL: <https://www.sciencedirect.com/science/article/pii/S0304380003002035>, doi:[https://doi.org/10.1016/S0304-3800\(03\)00203-5](https://doi.org/10.1016/S0304-3800(03)00203-5).
45. Tang, G., Clark, M.P., Papalexiou, S.M., Ma, Z., Hong, Y., 2020. Have satellite precipitation products improved over last two decades? A comprehensive comparison of GPM IMERG with nine satellite and reanalysis datasets. *Remote Sensing of Environment* 240, 111697.
46. Voronina, P.V., Mamash, E.A., 2014. Classification of thematic monitoring for agriculture problems using remote sensing MODIS data. *Computational Technologies* 19, 76–102.
47. Wu, C.D., Chen, Y.C., Pan, W.C., Zeng, Y.T., Chen, M.J., Guo, Y.L., Lung, S.C.C., 2017. Land-use regression with long-term satellite-based greenness index and culture-specific sources to model PM_{2.5} spatial-temporal variability. *Environmental Pollution* 224, 148–157.
48. Xing, N., Huang, W., Xie, Q., Shi, Y., Ye, H., Dong, Y., Wu, M., Sun, G., Jiao, Q., 2020. A transformed triangular vegetation index for estimating winter wheat leaf area index. *Remote Sensing* 12, 16.
49. Yamazaki, D., Ikeshima, D., Sosa, J., Bates, P.D., Allen, G.H., Pavelsky, T.M., 2019. MERIT hydro: a high-resolution global hydrography map based on latest topography dataset. *Water Resources Research* 55, 5053–5073.
50. Zhang, R., Nie, F., Li, X., Wei, X., 2019. Feature selection with Multiview data: A survey. *Information Fusion* 50, 158–167.
51. Zhou, Z., Guo, B., Xing, W., Zhou, J., Xu, F., Xu, Y., 2020. Comprehensive evaluation of latest GPM era IMERG and GSMaP precipitation products over mainland China. *Atmospheric Research* 246, 105132.
52. Токарев А.В. Разработка программно-технологического решения для формирования локального архива данных модели GFS. // Обработка пространственных данных в задачах мониторинга природных и антропогенных процессов (SDM-2023). Сборник трудов всероссийской конференции с международным участием, Новосибирск, 2023 – С. 156-162. DOI:10.25743/sdm.2023.78.14.027

НЕЙРОМОРФНАЯ СИСТЕМА НАВИГАЦИИ ДЛЯ АВТОНОМНЫХ МОБИЛЬНЫХ РОБОТОВ¹

А.М.Корсаков², В.В.Иванова², А.А.Демчева²

²Центральный научно-исследовательский и опытно-конструкторский институт
робототехники и технической кибернетики (ЦНИИ РТК), Россия, Санкт-
Петербург, a.korsakov@rtc.ru

Аннотация

В работе представлены результаты исследования возможности создания нейроморфной системы навигации для автономных мобильных роботов, основанной на нейроморфной системе принятия решений, которая, в свою очередь, строилась из отдельных универсальных нейроморфных модулей. Порядок и иерархия таких модулей и определяли поведение автономного мобильного робота. Для построения самих этих модулей использовались такие информационно-управляющие элементы, как детектор ситуации; логические элементы «И», «ИЛИ» и «НЕ»; нейроморфный экстраполятор; а также схема формирования условного рефлекса. В качестве базового элемента в предложенной системе выступает сегментная спайковая модель нейрона CSNM с возможностью структурного обучения. В работе приведены результаты исследования предложенной нейроморфной системы навигации для автономных мобильных роботов как на компьютерной модели, так и на реальном роботе.

Ключевые слова: нейроморфные системы, спайковый нейрон, нейроморфная система навигации

Введение

Вычислительные способности биологической нервной системы вдохновляют исследователей на разработку интеллектуальных вычислительных алго-

¹ Результаты получены в рамках выполнения государственного задания Минобрнауки России №075-00553-25-00 от 25.12.2024 «Исследование методов организации навигации роботов в сложных недетерминированных средах на базе теории когнитивного представления пространства» (FNRG-2025-0007 1024050200005-9-1.2.1;2.2.2)

ритмов и систем, которые могут обрабатывать информацию более точным, надежным и гибким образом [1]. Мозг обладает способностью эффективно интегрировать визуальное восприятие с процессом принятия решений в динамично меняющейся среде. Эффективная реализация комплексного интеллектуального поведения, от сенсорного ввода до выбора действий, имеет значение для понимания работы мозга и развития высокопроизводительного и энергоэффективного искусственного интеллекта, построенного на принципах работы нервной системы.

В настоящей работе рассматривается возможность построения нейроморфной системы навигации для автономных мобильных роботов, построенной на сегментной спайковой модели нейрона CSNM. Концепция построения такой системы предполагает использование отдельных универсальных нейроморфных модулей системы принятия решений, набор и иерархия которых и задают требуемое поведение мобильного робота. Высокая открытость такого подхода позволит расширять возможности интеллектуального биологически инспирированного поведения, в потенциале и за счёт реализации на масштабируемых архитектурах параллельных вычислений.

1. Нейроморфные информационно-управляющие элементы

В данной работе мы описываем использование нейроморфных информационно-управляющих элементов (НИУЭ) в качестве блоков-решателей при формировании сценария работы робота. Кратко перечислим предлагаемые нейроморфные информационно-управляющие элементы.

Нейроморфный детектор состояния — это обученный нейрон CSNM (англ. Compartmental Spiking Neuron Model) способный решать задачу бинарной классификации [2]. Данная модель нейрона используется нами в качестве базового элемента.

Важной особенностью используемой модели нейрона является возможность реализации на ней таких логических элементов, как «И» [3], «ИЛИ» [2] и «НЕ» [4], причём для реализации каждого из этих элементов необходим всего один нейрон CSNM.

В работе [3] авторами рассматривается схема формирования условного рефлекса, построенная на CSNM. В результате экспериментов было показано, что при одновременной подаче на входы схемы условного и безусловного раздражителей, через некоторое (определённое параметром) время, для вызова безусловной реакции становится достаточно подачи только условного раздражителя, что и означает завершение формирования условного рефлекса.

В работе [4] авторами была предложена схема нейроморфного экстраполятора. Схема представляет собой структуру элементарной ячейки сети, на выходе которой формируется прогнозируемое значение входного сигнала в следующий момент времени. Элементы ячейки выполняют операции суммирования и вычитания по аналогии с биологическими нейронами. Преимущество такой модели экстраполятора состоит в простоте вычислений и реализации алгоритма. Прогнозируемые значения любых монотонно изменяющихся сигналов, поступающих на входы ячейки, вычисляются в реальном масштабе времени без перестройки связей между элементами. Значения сигналов вычитаются и суммируются с единичными коэффициентами, что не требует ни специфического обучения с внешним учителем, ни критериев для аппроксимации выхода к входному сигналу, ни восстановления описывающей его функции или функциональной зависимости.




Рис. 1. Структура универсального нейроморфного модуля (УНМ) для формирования действий робота с использованием НИУЭ

2. Общая концепция нейроморфного механизма управления навигационным заданием при отработке сценария работы мобильного робота

Рассмотрим механизм формирования действий робота с использованием

в качестве блоков-переключателей универсальных нейроморфных модулей. Структура такого модуля показана на рисунке 1.

Для формирования универсальных нейроморфных модулей (УНМ) используются перечисленные выше НИУЭ.

Блок «CSNM – детектор ситуации» на рисунке 1 соответствует НИУЭ «нейроморфный детектор состояния». Будучи предварительно обучен, он решает задачу бинарной классификации текущей ситуации. Примером такой ситуации может выступать приближение к препятствию. Блок «Нейроморфный экстраполятор» соответствует НИУЭ «нейроморфный экстраполятор» и может заранее прогнозировать возникновение той или иной ситуации. Блок «Обработчик ситуации», как и блок «Решение» реализуют логику функционирования робота верхнего уровня и могут быть реализованы как традиционными способами, так и с использованием НИУЭ.

Предлагаемый механизм управления заданием сводится к следующему. УНМ, используемым в качестве блоков-переключателей, присваиваются приоритеты. Детектирование той или иной ситуации выполняется посредством УНМ, приоритет которого выше, что приводит к торможению всех УНМ, приоритет которых ниже данного. Добавляя, либо удаляя УНМ, а также меняя их приоритетность, мы получаем требуемое для нас поведение мобильного робота.

Построение такой иерархии УНМ проиллюстрируем на примере, который мы будем использовать далее (рис. 2).




Рис. 2. Пример иерархии универсальных нейроморфных модулей

На рисунке 2 отдельные блоки соответствуют различным УНМ, красная стрелка показывает возрастание их приоритета. Поведение мобильного робота, которое реализуется при помощи иерархии, приведённой на рисунке 2, будет описано ниже.

3. Проведение экспериментов на компьютерной модели

Для апробации описанного выше механизма был реализован эмулятор на языке Python, позволивший задавать сцену (включая положение цели и стартовые положение и ориентацию мобильного робота), а также задавать необходимые параметры сцены и мобильного робота (линейную и угловую скорость и т.п.) (рис. 3). Задачей мобильного робота на данном этапе работы являлось движение к цели в помещении с перегородками.




Рис. 3. Эмулятор для исследования механизма управления заданием

При экспериментах в эмуляторе, считалось, что мобильный робот способен измерять направление на цель, которая обозначена на рисунке 3 красной окружностью.

Мобильный робот на рисунке 3 обозначен как общая начальная точка четырёх отрезков (трёх синих, и одного жёлтого). Необходимо отметить, что при экспериментах в эмуляторе мобильный робот рассматривался в качестве материальной точки, что считалось достаточным, для апробации метода. Сами отрезки отображают измеренное расстояние четырьмя установленными на мобильном роботе сенсорами – фронтальным (обозначен жёлтым цветом), левым, правым и задним (обозначены синим цветом) дальномерами – до реальных стен и перегородок. Показания заднего дальномера далее в расчётах не учитывались. Формулы расчёта направления на цель, реальных и виртуальных показаний дальномеров, расстояний до виртуальных стен мы не приводим, т.к. они сводятся к элементарным геометрическим операциям.

Для проведения эксперимента в эмуляторе будем использовать иерархию УНМ, представленную на рисунке 2. Приведём пошаговое описание поведения мобильного робота, которому соответствует такой набор и иерархия УНМ:

1. если цель достигнута, то безусловной реакцией робота является остановка,

2. если детектируется препятствие спереди, то в качестве безусловной реакции робота выбран поворот налево,

3. если детектируется малый угол (употребляя термины «большой» и «малый» угол, мы имеем в виду длину ребра угла, а не само его значение), то для правого угла безусловной реакцией является поворот налево, тогда как для левого угла – поворот направо,

4. если детектируется большой угол, то безусловной реакцией робота является движение прямо,

5. если детектируется цель справа при отсутствии препятствия справа, то безусловной реакцией робота является поворот направо; тогда как если детектируется цель слева при отсутствии препятствия слева, то безусловной реакцией робота является поворот налево,

6. если детектируется препятствие сбоку на опасной дистанции (слишком близко), то, в зависимости от результата обработки ситуации, робот либо движется прямо, либо поворачивает в сторону от препятствия,

7. если детектируется препятствие сбоку на комфортной дистанции, то, в зависимости от результата обработки ситуации, робот либо движется прямо, либо поворачивает в сторону от препятствия,

8. если детектируется препятствие сбоку на дискомфортной дистанции (слишком далеко), то, в зависимости от результата обработки ситуации, робот либо движется прямо, либо поворачивает в сторону препятствия,

9. если детектируется цель спереди, то безусловной реакцией робота является движение прямо.

Таким образом задание робота можно охарактеризовать, как «движение к цели на комфортном расстоянии от препятствий».

Как видно из рисунка 3, с началом работы робот движется в направлении цели пока не упирается в виртуальную стену. Дальнейшее поведение робота соответствует пунктам 1-9 набора и иерархии УНМ, приведённым выше. Отдельно отметим стремление робота держаться на «комфортном» для себя расстоянии от виртуальной стены. Как видно из рисунка 3, в результате работы программы на данном примере, цель была достигнута. Используемые при проведении эксперимента параметры представлены в таблице.

Используемые параметры сцены и мобильного робота

Параметр	Значение
Угловая скорость МР	9° / такт обработки
Линейная скорость МР	0,1 м / такт обработки
Ширина опасной зоны у стены	0,3 м
Ширина комфортной зоны у стены	0,3 м
Ширина дискомфортной зоны у стены	0,6 м
Ребро малого угла	1,2 м
Ребро большого угла	$1,2 \cdot \sqrt{2}$ м

4. Проведение эксперимента на мобильном роботе

Целью натурного эксперимента было воспроизведение на мобильном роботе описанного ранее поведения, т.е. обучение робота движению на «комфортном» расстоянии от стены. В ходе эксперимента робот перемещался по замкнутому пространству. С целью избежать реальных столкновений робота со стеной из всех показаний дальномера в ходе рассматриваемого эксперимента вычиталось фиксированное значение (20 см).

На рисунке 4 представлены результаты эксперимента. Из начального состояния (А) робот доехал до стены. После поворота налево из-за срабатывания детектора большого угла мобильный робот оказался в зоне, где сработал детектор движения на комфортном расстоянии от препятствия (Б). Продолжая движение прямо, робот попал в зону срабатывания детектора движения на дискомфортном расстоянии (В), повернул направо (Г), сделал шаг вперед, далее снова

оказался в комфортной зоне и поехал прямо. Т.к. движение к стене осуществлялось под углом, сработал детектор малого угла (Д), робот повернул налево и снова попал в зону «комфортного расстояния», на котором и продолжил своё движение.

Для удобства определения ситуации на верхней части робота было установлено цифровое табло. Так, например, цифре 0 соответствует начальное состояние, цифре 2 – малый угол, 7 – комфортная дистанция, 8 – дискомфортная дистанция.

Таким образом, наблюдаемое в ходе натурного эксперимента поведение мобильного робота показало соответствие составу и иерархии выбранных УНМ.




Рис. 4. Результат натурного эксперимента

Заключение

На примере построения системы навигации для автономных мобильных роботов в работе предложена концепция построения нейроморфной системы принятия решений. Данная концепция подразумевает использование отдельных нейроморфных модулей системы принятия решений. Набор и иерархия таких

модулей и задают требуемое поведение объекта управления (мобильного робота). Сами нейроморфные модули системы принятия решений предлагается строить универсальным образом, с одним и тем же набором нейроморфных информационно-управляющих элементов, которые также были описаны в настоящей работе. В качестве базового элемента предложенной нейроморфной системы принятия решений использовалась сегментная спайковая модель нейрона CSNM с возможностью структурного обучения.

В статье представлены результаты компьютерного моделирования в специально разработанном для этой цели эмуляторе. Кроме того, приведены результаты натурных испытаний на мобильном роботе. Эксперименты показали принципиальную применимость предложенного подхода.

Список литературы

1. Lillicrap T.P. Backpropagation and the brain / T.P. Lillicrap, A. Santoro, L. Marris [и др] // Nature Reviews Neuroscience. — 2020. — Т. 21. — № 6. — С. 335—346.
2. Корсаков А.М. Применение сегментной спайковой модели нейрона со структурной адаптацией для решения задач классификации / А.М. Корсаков, Л.А. Астапова, А.В. Бахшиев // Информатика и автоматизация. — 2022. — Т. 21. — № 3. — С. 493—520.
3. Корсаков А.М. Реализация поведенческих функций на спайковых нейронных сетях / А.М. Корсаков, А.В. Бахшиев, Л.А. Астапова, Л.А. Станкевич // Информатика и автоматизация. — 2021. — Т. 20. — № 3. — С. 590—621.
4. Демчева А.А. Предупреждение возникновения критических ситуаций в сложных технических системах с использованием нейроморфного подхода / А.А. Демчева, А.М. Корсаков, И.С. Фомин [и др] // Робототехника и техническая кибернетика. — 2023. — Т. 11. — № 4. — С. 281—291.

ПРЕДСКАЗУЕМОСТЬ СОБЫТИЙ В ПРЕДЕЛЬНЫХ МОДЕЛЯХ МИРА ВЛИЯЕТ НА ФОРМИРОВАНИЕ УНИВЕРСАЛЬНОГО НАВЫКА РЕФЛЕКСИИ

Г.М. Маркова^{1,2}, С.И. Барцев^{1,2}

¹Институт биофизики СО РАН, *markova-g-m@yandex.ru*

² Сибирский федеральный университет,
Институт фундаментальной биологии и биотехнологии, каф.биофизики
bartsev@yandex.ru

Жизнь любого организма связана с выявлением наиболее существенных закономерностей окружающей среды, а также их использованием для достижения цели [1, 2], которая в общем случае представляет собой выживание. Внутреннее представление о среде, или репрезентация внешнего мира, требуется для реализации когнитивной функции, которую мы, вдохновляясь идеями В.А. Лефевра [3], называем рефлексией в широком смысле. Формирование таких репрезентаций в процессе освоения организмом окружающей среды связано с предсказуемостью событий этого мира [4, 5], поскольку сами репрезентации необходимы для того, чтобы живущий в среде организм мог предсказывать ее события и выбирать поведение, наиболее адекватное ситуации. Известно, что в непредсказуемой среде организмы формируют иные поведенческие стратегии, чем в предсказуемой [6], которые могут включать более агрессивное или импульсивное поведение [7]; также могут наблюдаться изменения в когнитивных функциях [8]. Интерес представляет вопрос о том, как предсказуемость осваиваемой организмом среды влияет на формирование у него рефлексии в широком смысле, как универсального навыка, с помощью которого организм может запоминать и распознавать паттерны событий внешнего мира, ранее ему неизвестные, а также формировать адекватное поведение.

Используемый нами метод эвристического (в смысле фон Неймана) нейросетевого моделирования позволяет выявлять наиболее общие закономерности исследуемого феномена – рефлексии в широком смысле. В рамках данного

метода, в качестве испытуемых мы используем эвристические модельные объекты – искусственные нейронные сети [9, 10]. Применимость объектов такого типа для моделирования когнитивных функций и, в частности, рефлексии обоснована в нашей работе [11].

Для формирования репрезентаций внешнего мира необходимо поместить эвристический модельный объект в соответствующую среду. Мы выделяем линейку абстрактных моделей мира, предельных с точки зрения информационного взаимодействия: среда случайных событий, среда-соперник, среда кусочно-регулярных событий, среда полностью регулярных событий. Общее свойство данных сред – наличие потока дискретных событий (стимулов), которые предъявляются модельному объекту, и формирует на каждое событие отклик, адекватность (правильность) которого оценивается по заранее заданному правилу. В таком случае модель мира может задаваться как условия некоторой задачи.

Среда полностью регулярных событий, в предельном случае, представляет собой последовательное предъявление одной и той же фиксированной последовательности стимулов, что является примером абсолютно предсказуемого окружения. Среда кусочно-регулярных, или периодически воспроизводимых событий, является менее предсказуемой: предъявляются несколько фиксированных последовательностей стимулов (временных рядов), и задача сводится не только к реагированию, но и распознаванию ряда при его подаче, что требует наличия внутренних представлений для каждого ряда [12]. Среда-соперник представляет собой мир, который «уклоняется» от предсказания и не содержит фиксированных последовательностей. Условия такого мира могут быть представлены как рефлексивная игра, где противник РНС – это, например, другая РНС [13]. В предельно непредсказуемой среде события выбираются из некоторого ограниченного набора случайным образом. В рамках такого мира невозможно поведение, допускающее безошибочное предсказание, и интерес представляет итоговое равновесное состояние, возникающее в итоге «освоения» мира.

В настоящей работе мы проверяем, формируется ли универсальный навык рефлексии в широком смысле у эвристических модельных объектов – простых

рекуррентных нейронных сетей (РНС) при освоении задач, представляющих собой предельные модели мира. Предполагается, что если универсальный навык рефлексии сформирован, то при тестировании на новой, ранее неизвестной задаче РНС продемонстрируют результат (долю правильных откликов) как минимум не хуже, чем РНС, изначально обученные на этой задаче. Мы также оцениваем структурную и нейрональную характеристику РНС после освоения первичной задачи, что в совокупности дает наиболее полное представление о влиянии условий предельной модели мира на способность модельного объекта к предсказанию событий.

В работе использовались гомогенные 30-нейронные РНС, функционирующие в дискретном режиме согласно формулам:

$$\alpha_i^{n+1} = \frac{\rho_i^n}{a + |\rho_i^n|}, \quad \rho_i^n = \sum_j w_{ij} \alpha_j^n + A_i^n \quad (1)$$

где α_j^n это выходной сигнал j -го нейрона на n -ом такте; w_{ij} это матрица весовых коэффициентов РНС; A_i^n это входной сигнал, поданный на i -ый нейрон на n -ом такте; a это константа, определяющая крутизну переходной характеристики нейрона. Начальные веса РНС задавались случайным образом в диапазоне $(-0.025; 0.025)$. РНС данного типа использовались нами в предыдущих работах [11 – 13]. Рекуррентность необходима, поскольку благодаря такой структуре сети нейронов возможно автономное существование внутренних репрезентаций предшествующих состояний рецепторов и возникновение осцилляций в нейронной активности [14, 15].

Сначала проводилось первичное обучение РНС одной из задач: рефлексивные игры, реагирование на фиксированные временные ряды стимулов (кратко – ряды), реагирование на единственную фиксированную последовательность стимулов (кратко – регулярную последовательность), реагирование на случайную последовательность стимулов. Правильность откликов РНС определялась по двум вариантам правил: соответствующим игре чет-нечет (ЧН) и камень-ножницы-бумага (КНБ).

Правила ЧН подразумевают наличие двух возможных стимулов: «0» и «1»,

задача РНС – сделать тот же ход, что и противник (или квазипротивник - временной ряд), т.е. РНС в данном эксперименте играют за позицию «чет». Стимул «0» подавался на два входа РНС как 01, «1» - как 10. Отклик РНС определялся похожим образом по соотношению сигналов на двух выходных нейронах. По правилам КНБ, возможны три стимула: «0», «1», «2» («камень», «ножницы», «бумага»), а задача РНС – сделать ход, побеждающий ход противника или квазипротивника.

В задаче реагирования на временные ряды стимулов использовались 4 ряда с повторяющимися сегментами длины 6 (например, 101001), сгенерированные с помощью генератора случайных чисел. Через каждые 60 тактов происходило переключение на следующий ряд. В рефлексивных играх противниками РНС были РНС той же конфигурации и размера. В реагировании на регулярную последовательность использовался один ряд с сегментом длины 24, который также задавался с помощью генератора случайных чисел. В задаче реагирования на случайную последовательность каждый последующий стимул выбирался случайно. Первичное обучение составляло 100 000 тактов и происходило по алгоритму backprop с глубиной распространения 5 тактов и квадратичной функцией потерь.

В качестве проверочных задач мы использовали только рефлексивные игры и реагирование на ряды, поскольку из четырех рассматриваемых в настоящей работе задач именно их можно в полной мере считать задачами на рефлексивность в широком смысле, т.е. такими, где формирование внутренних представлений необходимо для успешного решения. В проверочной задаче ряды и РНС-противники генерировались заново. Тест проводился в течение 500 тактов, при этом веса РНС оставались модифицируемыми. При тестировании мы оценивали качество отклика РНС как долю правильных откликов: отношение количества побед к общему количеству тактов. Результаты РНС в проверочных задачах мы сопоставляли с таковыми у контрольной группы РНС, не обученных никаким задачам. Во всех группах использовалось по 100 РНС.

Реализация любой функции обеспечивается определенной структурой.

Оценить поведение системы в стационарном состоянии (т.е. по прошествии достаточно длительного времени) с помощью структурных параметров возможно при рассмотрении максимального собственного значения Якобиана (МСЯ) правой части уравнений, описывающих функционирование системы (1).

Также оценивалась нейрональная характеристика – доля РНС с определенным типом аттрактора нейронной активности, т.е. траектории в многомерном пространстве, где координаты точек – это сигналы на нейронах РНС на текущем такте. У РНС в рассматриваемых условиях могут формироваться аттракторы следующих типов: затухающий (устойчивая нулевая точка), циклический, устойчивая ненулевая точка, странный (квазихаотический) [13]. Рассматривалась траектория нейронной активности, возникающая у РНС с фиксированными весами после подачи инициирующего одиночного стимула.

Доли правильных откликов РНС в проверочных задачах приведены на Рис. 1.




Рис. 1. Доли правильных откликов РНС, первично обученных в разных задачах, при тесте на проверочных задачах: ряды и игра по правилам ЧН, ряды и игра по правилам КНБ. Контрольная группа – необученные РНС того же размера и конфигурации. Здесь и далее погрешности – стандартное отклонение.

Результаты РНС, обученных реагированию на ряды и регулярную последовательность, сопоставимы с таковыми у контрольной группы, хоть и не превысили их, т.е. при продолжительном обучении этим задачам, по крайней мере, не была утрачена возможность адаптации к новым условиям. Напротив, результаты РНС, обученных играм и реагированию на случайную последовательность, в основном значительно хуже, чем у контрольной группы (здесь и далее значимость оценивалась с помощью двухвыборочного t-теста с различными дисперсиями, $\alpha=0,05$). Исключение составляет проверочная задача игры ЧН, где РНС, обученные на случайной последовательности, продемонстрировали тот же результат, что и контрольная группа, что связано с их выходом на равновесное состояние, где вероятность выигрыша в игре ЧН составляет 50% (в игре КНБ около 33%).

После освоения первичных задач были определены доли РНС с различными типами свободного аттрактора после подачи одиночного стимула, инициирующего нейронную активность. Результаты приведены на Рис. 2.




Рис. 2. Доли РНС, первично обученных в разных задачах (указаны в названиях графиков), по типам траекторий нейронной активности после одиночного инициирующего стимула, в зависимости от продолжительности обучения.

При обучении на играх ЧН и КНБ наблюдаются разные распределения РНС по типам аттракторов, в то время как при обучении другим задачам конкретные правила приводят к малозаметным отличиям (Рис. 2). Между долями РНС при обучении в играх и на случайных последовательностях (особенно по правилам КНБ) наблюдается сходство (Рис. 2, верхний ряд), также как и при обучении на рядах и регулярной последовательности (там же, нижний ряд). Аналогичная «группировка» по первичным задачам наблюдалась ранее при оценке доли правильных откликов РНС в проверочной задаче (Рис. 1).

Странные аттракторы связаны с хранением информации о внешних стимулах в незатухающем паттерне нейронной активности [16] и характеризуются чувствительностью внутреннего состояния системы к внешним сигналам. Такие аттракторы отсутствуют у РНС при продолжительном обучении на случайной последовательности (Рис. 2), вместо этого возникает незатухающий паттерн другого типа – фиксированная ненулевая точка, не подразумевающий чувствительности системы. Иными словами, РНС, осваивавшим мир случайных событий, становится «безразлично», что именно поступает на вход. Это позволяет объяснить, почему в большинстве проверочных задачах на рефлекссию данные РНС показывают такой низкий результат (Рис. 1).

После освоения первичных задач в течение 100 000 тактов были рассчитаны средние абсолютные величины МСЯ, характеризующие структуру матриц весов РНС. Результаты приведены в таблицах 1 и 2.

РНС, обученные реагированию на ряды и регулярную последовательность, демонстрируют лучшие результаты в проверочных задачах (Рис. 1), а также обладают наименьшими средними абсолютными МСЯ по сравнению с РНС, обученными реагированию на случайную последовательность и играм (таблица 1 и 2). Этот результат иллюстрирует «жесткость» структуры РНС вследствие освоения труднопредсказуемых сред, таких как случайная среда и среда-соперник, что приводит к низкой эффективности в проверочных задачах (Рис. 1). Несколько неожиданный для нас результат заключается в том, что полностью регулярная среда, несмотря на отсутствие вариативности стимулов, напротив, способствует

сохранению адаптивных возможностей структуры РНС, что подтверждается как невысокими величинами МСЯ, так и успешностью в проверочных задачах. Возрастание МСЯ у РНС при освоении труднопредсказуемых сред объясняется увеличением весов РНС при неизбежных ошибках отклика.

Таблица 1

Средние абсолютные МСЯ, после освоения первичных задач с правилами ЧН

Задача	Игра ЧН	Случайная посл-ть (ЧН)	Ряды ЧН	Регулярная посл-ть (ЧН)
МСЯ	3,2±0,6	2,6±0,1	1,9±0,3	1,8±0,4

Таблица 2

Средние абсолютные МСЯ, после освоения первичных задач с правилами КНБ

Задача	Игра КНБ	Случайная посл-ть (КНБ)	Ряды КНБ	Регулярная посл-ть (КНБ)
МСЯ	2,2±0,3	2,9±0,1	1,7±0,2	1,6±0,2

Полученные результаты позволяют заключить, что наиболее важная характеристика потока событий в среде, с точки зрения рефлексии, это его воспроизводимость. Условия среды-соперника, которые были смоделированы в рамках задачи рефлексивных игр, не содержат предзаданной повторяемости стимулов ходов соперника, хотя она может появиться при выборе ходов РНС-игроками сама по себе. Однако в экспериментах показано, что данный процесс либо не происходит, либо его масштабы незначительны. Поэтому условия среды, моделируемой в игре, для РНС почти так же непредсказуемы, как случайная последовательность стимулов, что затрудняет формирование внутренних представлений и универсального навыка рефлексии при тестировании не наблюдается.

В свою очередь, регулярность внешних событий способствует формированию внутренних представлений, благодаря чему происходит распознавание типичных паттернов среды и соответствующая правильная реакция, что мы также исследовали ранее [12, 13]. Даже если условия среды меняются, например, при

переходе от первичной задачи к проверочной, структура РНС уже организована для наиболее эффективного удержания внутренних представлений, в частности, с помощью сохранения информации в незатухающем паттерне нейронной активности, чувствительном к внешним воздействиям, который представляет собой странный (квазихаотический) аттрактор.

По совокупности характеристик (формальная – доля правильных откликов в проверочной задаче, нейрональная – доля РНС со странным аттрактором после освоения первичной задачи, структурная – величина МСЯ после освоения первичной задачи), из рассмотренных предельных абстрактных сред кусочно-регулярная среда в наибольшей степени способствует формированию универсального навыка рефлексии. Данный результат согласуется с литературными данными о значимости регулярных событий для живых организмов [10, 17], а также о том, что труднопредсказуемость событий внешнего мира – это негативный стрессовый фактор [6, 7].

Полученные результаты позволяют уточнить наше представление о рефлексии в широком смысле, основанной на внутренних представлениях внешнего мира, и упрощают выбор условий среды для дальнейших исследований данного явления.

Список литературы

1. Erdin H. O. Representing is something that we do, not a structure that we “use”: Reply to Gładziejewski / H. O.Erdin, M. H.Bickhard // New Ideas in Psychology. – 2018. – Vol. 49. – P. 27–37.
2. Verschure P. F. M. J. The why, what, where, when and how of goal-directed choice: neuronal and computational principles / P.F.M.J.Verschure, C.M.A.Pennartz, G.Pezzulo // Philosophical Transactions of the Royal Society B: Biological Sciences. – 2014. – Vol. 369. – P. 20130483.
3. Lefebvre V. A. The fundamental structures of human reflection / V.A.Lefebvre // Journal of Social and Biological Structures. – 1987. – Vol. 10, № 2. – P. 129–175.
4. Conway C. M. How does the brain learn environmental structure? Ten core principles for understanding the neurocognitive mechanisms of statistical learning /

- C.M.Conway // Neuroscience & Biobehavioral Reviews. – 2020. – Vol. 112. – P. 279–299.
5. Goekoop R. Hierarchical network structure as the source of hierarchical dynamics (power-law frequency spectra) in living and non-living systems: How state-trait continua (body plans, personalities) emerge from first principles in biophysics / R.Goekoop, R.de Kleijn // Neuroscience & Biobehavioral Reviews. – 2023. – Vol. 154. – P. 105402.
 6. Yang A. T. Environmental harshness and unpredictability, parenting, and offspring life history / A.T.Yang, H.J.Lu, L.Chang // Evolutionary Psychological Science. – 2023. – Vol. 9, № 4. – P. 451–462.
 7. Fenneman J. Is impulsive behavior adaptive in harsh and unpredictable environments? A formal model / J. Fenneman, W.E. Frankenhuys // Evolution and Human Behavior. – 2020. – Vol. 41, № 4. – P. 261–273.
 8. Pietto M. L. Perceived levels of environmental unpredictability and changes in visual attention mechanisms in adults / M.L.Pietto, F.Giovannetti, J.Hermida, M.S.Segretin, S.J.Lipina, J.E.Kamienkowski // Behavioural Brain Research. – 2025. – P. 115601.
 9. Baciú D. C. Neural networks through the lens of evolutionary dynamics / D.C.Baciú // BioSystems. – 2025. – Vol. 248. – P. 105386.
 10. Барцев С. И. Эвристические нейросетевые модели в биофизике: приложение к проблеме структурно-функционального соответствия / С.И.Барцев, О.Д.Барцева. – Сибирский федеральный университет, 2010. – 114 с.
 11. Барцев С. И. Биофизический подход к моделированию рефлексии: обоснование, методы, результаты / С.И.Барцев, Г.М.Маркова, А.И.Матвеева // Философские проблемы информационных технологий и киберпространства. – 2023. – № 2. – С. 120–139.
 12. Markova G. M. Decoding Neural Activity of the Simplest Heterogeneous Neural Networks / G.M.Markova, S.I.Bartsev // In: Advances in Neural Computation, Machine Learning, and Cognitive Research VIII. NI 2024. Studies in Computational Intelligence. Eds. V.Redko, D.Yudin, W.Dunin-Barkowski, B.Kryzhanovsky,

- Y.Tiumentsev // Springer, Cham. – 2025. – Vol. 1179. – P. 362-371.
13. Маркова Г. М. Предельно просто не значит предельно ясно: некоторые контринтуитивные результаты нейросетевого моделирования рефлексии / Г.М.Маркова, С.И.Барцев // Информационные и математические технологии в науке и управлении. – 2025. – № 1 (37). – С. 5–15.
14. Kaplan H. S. Sensorimotor integration in *Caenorhabditis elegans*: a reappraisal towards dynamic and distributed computations / H.S.Kaplan, A.L.A.Nichols, M.Zimmer // Phil. Trans. R. Soc. B. – 2018. – Vol. 373. – P. 20170371.
15. Lamme V. A. F. Challenges for theories of consciousness: seeing or knowing, the missing ingredient and how to deal with panpsychism / V.A.F.Lamme // Philosophical Transactions of the Royal Society B: Biological Sciences. – 2018. – Vol. 373, № 1755. – P. 20170344.
16. Stroud J. P. The computational foundations of dynamic coding in working memory / J.P.Stroud, J.Duncan, M.Lengyel // Trends in Cognitive Sciences. – 2024. – Vol. 28, № 7. – P. 614–627.
17. Kanaev A. I. The Evolutionary Pathway to Consciousness and Reason: the Cognitome from a Philosophical Perspective / A.I.Kanaev, E.D.Dryaeva // Neuroscience and Behavioral Physiology. – 2023. – Vol. 53. – № 7. – P. 1146–1157.

МНОГОУРОВНЕВОЕ АДАПТИВНОЕ ВОССТАНОВЛЕНИЕ ИНФРАКРАСНЫХ ИЗОБРАЖЕНИЙ ДИКИХ ЖИВОТНЫХ

Д.Н. Наталенко

ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева», г. Красноярск

Введение. Фоторегистраторы широко применяются для мониторинга дикой природы и наблюдения за животными в естественной среде обитания. Они позволяют получать визуальные данные без непосредственного вмешательства человека, что важно для изучения поведения и численности животных [1]. Особенно ценной оказывается возможность работы в ночное время с использованием инфракрасной (ИК) подсветки, что расширяет диапазон наблюдений и обеспечивает круглосуточный сбор информации.

Качество ИК-изображений, получаемых от фоторегистраторов, существенно зависит от условий съемки, включая уровень освещенности, погодные условия и параметры сенсоров. Плохая освещенность и особенности инфракрасной съемки приводят к значительному уровню шума и искажений, ухудшающих визуальную информативность снимков. Цифровой шум, погодные артефакты и низкая детализация затрудняют выделение контуров и мелких текстур, что снижает эффективность последующего анализа и интерпретации данных [2].

В последние годы в задачах мониторинга дикой природы все шире применяются нейронные сети и другие методы машинного обучения, которые позволяют эффективно классифицировать объекты, распознавать поведение животных и извлекать значимые признаки из изображений [3-5]. Однако качество работы таких систем напрямую зависит от исходного качества данных. Наличие шумов и искажений существенно снижает точность распознавания, увеличивает вероятность ложных срабатываний и затрудняет обучение моделей.

Для повышения качества ИК-снимков необходимы эффективные методы восстановления, способные адаптивно подавлять шумы, повышать контрастность и восстанавливать детали изображения. Современные методы глубокого

обучения демонстрируют значительный потенциал в решении этих задач, позволяя создавать многоуровневые модели, которые имитируют биологические механизмы зрительной обработки и адаптируются к изменяющимся условиям съемки [6].

Постановка задачи. Задача многоуровневого адаптивного восстановления ИК-изображений, получаемых от фоторегистраторов заключается в автоматическом восстановлении приближенного к истинному изображению сцены на основе зашумленного и искаженного наблюдения. Исходные изображения Y характеризуются низкой освещенностью, наличием сложного шума и искажениями, вызванными погодными условиями, а также вариативностью параметров съемки. Все это значительно затрудняет последующий анализ и распознавание объектов.

Для успешного решения задачи восстановления необходимо выполнить последовательную обработку, включающую следующие взаимосвязанные этапы:

- шумоподавление, направленное на уменьшение влияния цифрового шума и артефактов, возникающих при инфракрасной съемке, что обеспечивает повышение четкости и снижает искажения изображения;
- адаптивное повышение контрастности и коррекцию освещения, позволяющие улучшить визуальное восприятие деталей и выделить важные структурные элементы сцены;
- сверхвысокое разрешение, обеспечивающее восстановление высокочастотных деталей и увеличение пространственного разрешения итогового изображения.

Каждый из перечисленных этапов формализуется с помощью параметрических функций F_1 , F_2 , F_3 , параметризованных векторами Θ_1 , Θ_2 , Θ_3 соответственно, и адаптируется с учетом контекстных параметров съемки, объединенных в вектор $c = [c_1, c_2, \dots, c_m]$, включающий уровень шума, освещенность и другие характеристики.

Результатом первого этапа обработки является изображение Y_1 , в котором подавлена значительная часть шума (1):

$$Y_1 = F_1(Y; \Theta_1), \quad (1)$$

где F_1 – функция шумоподавления, параметризованная Θ_1 .

Далее выполняется адаптивное повышение контрастности, позволяющее улучшить визуальное восприятие и выделить детали (2):

$$Y_2 = F_2(Y; \Theta_2), \quad (2)$$

где F_2 – функция повышения контрастности, параметризованная Θ_2 .

Завершающим этапом является применение метода сверхвысокого разрешения, направленное на восстановление высокочастотных деталей и увеличение пространственного разрешения изображения (3):

$$\hat{X} = F_3(Y; \Theta_3), \quad (3)$$

где F_3 – функция сверхвысокого разрешения, параметризованная Θ_3 , а $\hat{X}$ – итоговое восстановленное изображение.

Общая функция восстановления с учетом параметров контекста задается как (4):

$$X = F(Y, c; \Theta), \quad (4)$$

где $\Theta = \{\Theta_1, \Theta_2, \Theta_3\}$ – совокупность параметров модели.

Задача сводится к обучению параметров Θ модели, обеспечивающей минимизацию функции потерь, например, среднеквадратичной ошибки между восстановленным изображением $\hat{X}$ и оригинальным X (5):

$$L(\Theta) = E_{X,Y,c} \left[\frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W (\hat{X}_{ij} - X_{ij})^2 \right], \quad (5)$$

Таким образом, формулируется задача построения адаптивной многоуровневой модели, способной эффективно восстанавливать высококачественные ИК-изображения дикой природы с учетом изменяющихся условий съемки.

Предлагаемый метод. Для решения задачи многоуровневого адаптивного восстановления ИК-изображений предлагается архитектура нейронной сети, состоящая из трех последовательных уровней, каждый из которых решает специализированную подзадачу: шумоподавление, коррекция освещения и сверхвысокое разрешение.

Входное изображение сначала обрабатывается набором фильтров Габора, которые эффективно выделяют текстурные и структурные признаки, устойчивые к шуму и вариациям условий съемки. Эти признаки передаются на первый уро-

вень – модуль шумоподавления, построенный на основе сверточных блоков с остаточными связями (ResBlock) и механизмом внимания SE (Squeeze-and-Excitation). Данный модуль адаптивно усиливает важные каналы признаков, что позволяет улучшить качество шумоподавления. На этом этапе используется энкодер, который извлекает и преобразует признаки изображения, включая фильтры Габора, сверточные слои, остаточные блоки и SE-блоки.

Далее выходные данные передаются на второй уровень, который выполняет адаптивную коррекцию яркости и контраста. Этот уровень также реализован с использованием сверточных блоков и SE-механизма, что улучшает визуальную детализацию и восприятие мелких структур в изображении. Здесь работает декодер, который принимает преобразованные признаки от энкодера и улучшает их, применяя аналогичные компоненты для коррекции контраста.

Последний третий уровень осуществляет сверхвысокое разрешение с увеличением разрешения в 2 раза. Он использует сверточные блоки, SE-механизм и операцию PixelShuffle для эффективного восстановления высокочастотных деталей, что позволяет значительно улучшить качество итогового изображения.

Для более четкой организации процесса выделяются две основные подсистемы: первая подсистема отвечает за извлечение и преобразование признаков. Она включает в себя несколько сверточных блоков, которые последовательно обрабатывают входные данные, извлекая важные характеристики и адаптируя их с помощью механизма внимания. Вторая подсистема принимает эти преобразованные признаки и восстанавливает изображение, увеличивая его разрешение и улучшая качество.

Общая модель формализуется как (6):

$$(\hat{Y}_1, \hat{Y}_2, \hat{X}) = F(Y; \Theta), \quad (6)$$

где $\hat{Y}_1$ – результат шумоподавления, $\hat{Y}_2$ – результат коррекции освещения, $\hat{X}$ – итоговое сверхвысокое разрешение, а Θ – параметры всей модели.

Каждый уровень задачи (шумоподавление, коррекция освещения, сверхвысокое разрешение) функционирует как последовательный блок, принимая выход предыдущего блока в качестве входных данных. Такой подход позволяет

эффективно учитывать особенности ИК-изображений, адаптироваться к вариациям условий съемки и восстанавливать качественные изображения с сохранением деталей.

Наборы данных и обучение. Набор данных для обучения является синтетическим и поделен на две части под разные этапы обучения. Первая часть содержит тройки изображений: зашумленное инфракрасное изображение, соответствующее ему чистое изображение без шума и оригинал с улучшенным освещением, что позволяет одновременно обучать модель подавлять шум и корректировать освещение. Вторая часть содержит набор пар изображений с низким и высоким разрешением. Все изображения преобразуются к единому размеру с помощью аугментаций и преобразований, обеспечивая согласованность данных и стабильность обучения.

Набор данных для тестирования содержит реальные изображения, собранные с фоторегистраторов национального парка «Ергаки». Набор данных содержит зашумленные изображения дикой природы, снятых в различных условиях освещенности и погодных факторов.

Общее содержание наборов данных представлено в таблице 1.

Таблица 1

Наборы данных для обучения и тестирования

Набор данных	Тип данных	Содержание данных	Количество данных	Аугментации
Обучающий	Синтетический	Тройки изображений: зашумленное, чистое, контрастное	1000	Присутствуют: повороты, сдвиги, отражения
		Пары изображений: низкое разрешение, высокое разрешение	500	
Тестовый	Естественный	Одиночные изображения	500	Отсутствуют

Обучение модели проводится в два этапа с использованием специализированных наборов данных и функций потерь. На первом этапе проводится обучение уровней шумоподавления, а также коррекция яркости и контраста. Используется набор данных с парами изображений: зашумленное исходное изображение Y , оригинальное чистое изображение Y_{clean} и оригинальное изображение со скорректированным освещением Y_{light} .

Оптимизируется суммарная функция потерь (7):

$$L_{denoise+light} = MAE(\hat{Y}_1; Y_{clean}) + MAE(\hat{Y}_2; Y_{light}), \quad (7)$$

где $\hat{Y}_1, \hat{Y}_2$ – выходы первого и второго уровней модели.

На втором этапе проводится обучение уровня сверхвысокого разрешения в соответствии с методом пост-увеличения разрешения (Post-Upsampling). Используется набор данных пар изображений низкого разрешения Y_{LR} и соответствующими изображениями высокого разрешения Y_{HR} .

Оптимизируется функция потерь (8):

$$L_{superres} = MAE(\hat{X}; Y_{HR}), \quad (8)$$

где $\hat{X}$ – выход уровня сверхвысокого разрешения.

Обучение на обоих этапах проводится с использованием оптимизатора Adam, который обеспечивает эффективное обновление весов и адаптивное изменение скорости обучения. Для повышения производительности вычислений и снижения потребления видеопамати применяется технология автоматического смешанного точного вычисления (Automatic Mixed Precision, AMP). В рамках AMP используется механизм GradScaler, который помогает избежать переполнения градиентов, что важно в условиях ограниченной видеопамати. Каждый этап обучения продолжается в течение 100 эпох с мониторингом функции потерь и времени обучения.

Экспериментальные результаты. Для количественной оценки качества восстановления применялись неэталонные показатели качества BRISQUE (Blind/Referenceless Image Spatial Quality Evaluator), NIQE (Naturalness Image Quality Evaluator) и FIDE (Fidelity, Intelligibility, Distortion, and Effectiveness). Для оценки эффективности коррекции освещения, направленной на улучшение ярко-

сти, контраста и визуальной информативности ИК-изображений, использовались неэталонные показатели качества: LOE (Lightness Order Error), MC (Michelson Contrast) и энтропия.

Совместное использование этих метрик обеспечивает всестороннюю и объективную оценку эффективности алгоритмов коррекции, позволяя учитывать, как технические, так и визуальные аспекты качества результата.

Результаты тестирования метода на шумоподавление, а также сравнение его работы с другими методами, представлено в таблице 2.

Таблица 2

Средние значения тестирования шумоподавления по метрикам

Метод	BRISQUE ↓		NIQE ↓	
	до	после	до	после
Median Filter	45,20	38,55	6,80	5,45
Non-Local Means		36,80		5,23
Wavelet Denoise		37,26		5,36
Total Variation		36,39		4,91
Предлагаемый метод		33,82		4,53

Предлагаемый метод демонстрирует заметное улучшение качества шумоподавления по сравнению с классическими алгоритмами. Снижение значений BRISQUE свидетельствует о том, что предлагаемый метод более эффективно устраняет шум и улучшает визуальное качество изображений. В то же время снижение показателей NIQE указывает на то, что предлагаемый метод не только снижает шум, но и сохраняет структурные и текстурные характеристики изображения более эффективно, чем другие методы.

Результаты тестирования метода на коррекцию освещения, а также сравнение его работы с другими методами, представлены в таблице 3.

Таблица 3

Средние значения тестирования коррекции освещения по метрикам

Метод	LOE↓		MC↑		Entropy↑	
	до	после	до	после	до	после
CLANE	0,62	0,45	0,35	0,50	7,12	7,83
MSR		0,38		0,53		8,12
HDR		0,47		0,44		7,86
Предлагаемый метод		0,30		0,54		8,54

Предлагаемый метод коррекции освещения показывает наилучшие результаты по всем метрикам. Значительное снижение LOE свидетельствует о более точном сохранении порядка яркости, что важно для восприятия деталей. Рост значений Michelson Contrast указывает на улучшение контрастности изображения, что повышает визуальную информативность. Рост энтропии говорит о возрастании детализации и текстурной сложности.

Визуальное сравнение результатов до и после коррекции показано на рисунке.



Рис. Результаты коррекции ИК-изображений: а) оригинальные изображения, б) восстановленные изображения

Исходя из результатов визуальной оценки, можно сделать вывод о том, что предлагаемый метод отлично справляется с шумоподавлением, а также восстанавливает более четкие контуры и текстуры, что особенно важно для анализа

природных объектов в ночных условиях. К сожалению, метод не способен восстановить особенно темные участки, однако с освещенными участками он работает эффективно, обеспечивая значительное улучшение качества изображения.

Итоги экспериментов подтверждают, что предложенный многоуровневый подход с использованием фильтров Габора и SE-механизма внимания обеспечивает значительное улучшение качества восстановления ИК-изображений диких животных по сравнению с классическими и современными методами. Адаптивное включение контекстных параметров съемки позволяет модели эффективно работать в различных условиях, что важно для практического применения в системах мониторинга дикой природы.

Заключение. В данной работе представлена многоуровневая адаптивная модель восстановления ИК-изображений диких животных с фоторегистраторов, включающая три ключевых этапа: шумоподавление, коррекцию освещения и сверхвысокое разрешение.

Экспериментальные результаты показывают значительное превосходство модели по ключевым метрикам качества. В шумоподавлении достигнуто снижение BRISQUE и NIQE (33,82 и 4,53), что подтверждает более качественное удаление шума. В коррекции освещения метод снизил LOE (0,30), что указывает на точное сохранение порядка яркости, а также увеличил Michelson Contrast (0,54) и энтропию (8,54), что свидетельствует о лучшей передаче визуальной информации.

Визуальный анализ подтверждает восстановление четких контуров и текстур, значительно улучшая качество изображений. Таким образом, разработанная модель является эффективным инструментом для повышения качества ИК-изображений дикой природы.

Таким образом, разработанная многоуровневая адаптивная модель восстановления является эффективным инструментом для повышения качества ИК-изображений дикой природы.

Список литературы

1. Огурцов С.С. Фотомониторинг на заповедных территориях: программа САМ-

- MON (Основной модуль). Первая редакция / С. С. Огурцов. — М.: Т-во научных изданий КМК, 2025. — 337 с.
2. Наталенко Д.Н. Влияние предварительной обработки изображений на точность распознавания диких животных / Д.Н. Наталенко // Решетневские чтения : Материалы XXVIII Международной науч. конф. в 2-х ч. — 2024. — С. 326–328.
 3. Norouzzadeh M. A deep active learning system for species identification and counting in camera trap images / M. Norouzzadeh, D. Morris, S. Beery et al. // *Methods in Ecology and Evolution*. — 2020. — Vol. 12, № 3. — P. 150-161.
 4. Whytock R. Robust ecological analysis of camera trap data labelled by a machine learning model / R. Whytock, J. Świeżewski, J. Zwerts et al. // *Methods in Ecology and Evolution*. — 2021. — Vol. 12, № 1. — P. 1080-1092.
 5. Fennell M. Use of object detection in camera trap image identification: Assessing a method to rapidly and accurately classify human and animal detections for research and application in recreation ecology / M. Fennell, C. Beirne, C. Burton // *Global Ecology and Conservation*. — 2022. — Vol. 35. — Art. No. e02104.
 6. Dakshayani V. Design of a Gabor Filter-Based Image Denoising Hardware Model / V. Dakshayani, G. Locharla, P. Pławiak, V. Datti, C. Karri // *Electronics*. — 2022. — Vol. 11, № 7. — Art. No. 1063.

QUALITY METRICS FOR MRI-CT FUSION IN ABDOMINAL IMAGING: A NOVEL HYPOTHESIS FOR EVALUATION

N. Nishchhal¹

¹Reshetnev Siberian State University of Science and Technology,
Institute of Informatics and Telecommunications, *nik.321g@yandex.ru*

Introduction

Medical image fusion, particularly the integration of Magnetic Resonance Imaging (MRI) and Computed Tomography (CT) data, plays a critical role in abdominal diagnostics, surgical planning, and radiotherapy. MRI excels in soft tissue contrast and functional information while CT provides superior spatial resolution and accurate Hounsfield unit-based tissue density information. The fusion of these modalities aims to combine their complementary strengths into a single, information-rich representation. However, assessing the quality of such fusion remains a challenge due to the absence of a ground truth and the complexity of anatomical structures in the abdomen [1].

Traditional fusion quality metrics often rely on intensity-based, structural similarity, or information-theoretic measures. While useful, these metrics may not fully capture the clinical utility or anatomical fidelity required in abdominal imaging, where organ deformation, respiratory motion, and partial volume effects are common. This paper reviews existing quality metrics for MRI-CT abdominal fusion and proposes a novel hypothesis: the introduction of a motion-aware, anatomy-preserving fusion quality index (MAFQI) that incorporates biomechanical modelling and regional structural consistency.

Review of Existing Quality Metrics

Quality metrics can be broadly categorized into reference-based and non-reference/no-reference (blind metrics). For MRI-CT fusion, where a true ground-truth fused image does not exist, most metrics are reference-based, using the original input images to evaluate the result. Several quantitative metrics are commonly used to evaluate image fusion performance:

Mutual Information (MI): Measures the statistical dependence between the fused image and the source images. High MI indicates good alignment and information transfer. However, MI is sensitive to noise and may not reflect anatomical accuracy.

Peak Signal-to-Noise Ratio (PSNR): Evaluates intensity fidelity relative to a reference (if available). Its utility is limited in multi-modal fusion where intensity distributions differ significantly.

Structural Similarity Index (SSIM): Assesses structural preservation by comparing luminance, contrast, and structure. While effective for single-modality comparisons, its direct application to MRI-CT fusion is problematic due to differing contrast mechanisms.

Edge-Based Metrics (e.g., QAB/F): Quantify how well edges from source images are preserved in the fused image. These are useful for assessing spatial fidelity but may overemphasize high-frequency noise.

Entropy and Information Transfer Metrics: Evaluate the amount of information from source images retained in the fusion. Examples include the Fusion Mutual Information (FMI) and Nonlinear Correlation Information Entropy (NCIE). These are sensitive to registration errors and noise.

Despite their widespread use, these metrics often fail to account for organ-specific deformation, motion artifacts (especially in abdominal imaging), and clinical interpretability. Furthermore, they assume static anatomical configurations, which is rarely the case in abdominal imaging due to respiratory and peristaltic motion [2,3].

Limitations in Abdominal MRI-CT Fusion Assessment

The abdominal domain introduces significant challenges for image fusion, including respiratory motion, peristalsis, and soft tissue deformation, which expose critical shortcomings in standard quality metrics like SSIM, MI, and gradient-based measures [4]. Firstly, these metrics lack clinical context as they operate on a pixel level, remaining agnostic to anatomical meaning; consequently, an algorithm may achieve a high overall score while failing catastrophically at a clinically critical interface, such as the boundary between a tumor and liver parenchyma. Secondly, they are notoriously insensitive to texture, failing to quantify the preservation of crucial MRI-derived tex-

tural patterns that are vital for diagnosis [5]. Finally, this can lead to the ghosting problem, where a fused image appears sharp and scores well on edge-based metrics yet contains subtle misalignments that create blurring or duplication of critical structures, potentially leading to serious targeting errors in applications like radiotherapy planning. Current metrics often treat fusion as a purely pixel-level optimization problem, neglecting physiological and biomechanical plausibility. For instance, a fusion result may score highly on MI or SSIM but misalign the liver dome due to breathing motion, leading to clinical misinterpretation [6].

A Novel Hypothesis: Motion-Aware, Anatomy-Preserving Fusion Quality Index (MAFQI)

Current methodologies for evaluating the quality of MRI-CT image fusion in abdominal imaging are predominantly grounded in information-theoretic or structural similarity measures that operate at the pixel or intensity level, such as mutual information (MI), structural similarity index (SSIM), and edge preservation metrics. While these metrics provide quantitative insight into the fidelity of information transfer between modalities, they are fundamentally limited in their ability to assess anatomical plausibility and physiological consistency critical factors in clinical interpretation. In abdominal imaging, where respiratory motion, peristalsis, and variable organ deformation significantly affect spatial alignment between MRI and CT acquisitions, conventional metrics may erroneously favor fusion results that are mathematically optimal but anatomically implausible. To address this gap, we propose a new quality metric framework: the Motion-Aware, Anatomy-Preserving Fusion Quality Index (MAFQI), which integrates biomechanical modeling and regional structural consistency to assess fusion accuracy in a clinically meaningful way.

Hypothesis:

Fusion quality in abdominal MRI-CT should be evaluated not only by information retention but also by the biomechanical plausibility of organ deformation and the preservation of anatomical topology across modalities. A fusion result that respects tissue elasticity, organ boundaries, and motion patterns will yield higher diagnostic confidence and clinical utility.

The MAFQI is engineered to operationalize the proposed hypothesis by providing a multi-faceted evaluation framework. It moves beyond monolithic scores to dissect fusion quality through three distinct yet complementary perspectives: the physical plausibility of the transformation, the structural fidelity within critical anatomical regions, and the integrity of information transfer after motion compensation. This tripartite approach ensures that a high-quality fusion is not merely a statistical optimum but a clinically trustworthy and physically realistic representation of the patient's anatomy.

1. Biomechanical Consistency Score (BCS)

The Biomechanical Consistency Score (BCS) introduces a paradigm shift by grounding quality assessment in the physical laws governing soft tissue deformation. Its core principle is to evaluate whether the deformation field Φ , generated by the registration algorithm to warp the moving image to the fixed image, is physically realistic. This is paramount in the abdomen, where organs undergo significant and complex motion; a fusion algorithm might produce a mathematically elegant solution that nevertheless violates basic biomechanical constraints, rendering it anatomically implausible and clinically hazardous.

The methodology for calculating the BCS is rigorous. It begins with the construction of a simplified Finite Element Model (FEM) of the key abdominal organs—such as the liver, kidneys, and spleen—which are segmented from the fixed CT scan. These organs are assigned well-established material properties from biomechanical literature, often modelled as hyper elastic materials with characteristic Young's Modulus and Poisson's ratio values. This virtual model is discretized into a mesh of elements. The simulation is driven by defining boundary conditions, typically based on the observed displacement of the diaphragm between the two scans, which provides the primary driving force for organ deformation. The FEM solver then computes a biomechanically plausible deformation field, Φ_{bio} .

This simulated field serves as a ground truth for physical realism. The actual registration-derived field, Φ_{reg} , is compared to Φ_{bio} using a suite of metrics designed to detect implausibilities. These include an analysis of the Jacobian determinant of Φ_{reg} to identify regions of unphysical tissue compression or expansion, a comparison of the

divergence of the two vector fields to highlight erroneous contraction or swelling, and a calculation of the deviation in strain energy, which penalizes deformations that would require unrealistic force. The final BCS output is a normalized score between 0 and 1, where 1 indicates a perfect agreement with the biomechanical simulation, effectively quantifying the physical plausibility of the fusion result.

2. Regional Structural Fidelity (RSF)

The Regional Structural Fidelity (RSF) component addresses the critical shortcoming of global metrics by focusing evaluation on clinically relevant anatomical structures. Its principle is that the preservation of structural information within specific organs and vascular networks is more important than a high overall similarity score, which can be biased by large, homogeneous regions. The RSF ensures that the fusion accurately maintains the architecture of critical areas, such as tumor margins and vascular trees, which are essential for diagnosis and treatment planning.

The RSF methodology starts with a sophisticated anatomical partitioning of the abdominal volume into distinct regions of interest (e.g., liver, kidneys, pancreas, major vessels) using atlas-based or deep-learning segmentation. Within each organ i , a modified Structural Similarity Index is computed between the fixed image and the fused image. Crucially, these regional scores are then weighted by clinical importance, allowing the metric to prioritize, for instance, the liver in a hepatobiliary oncology case.

Beyond simple intensity-based similarity, the RSF incorporates a deep topological analysis to assess the integrity of intricate structures. This involves applying vesselness filters to enhance tubular networks, followed by skeletonization to extract the underlying graph topology of systems like the hepatic vasculature. The metric then quantifies errors such as a change in the number of vascular branchpoints or a reduction in vessel continuity, applying significant penalties for topological errors that could indicate broken or disconnected vessels. A boundary sharpness metric further evaluates the preservation of organ margins. The final RSF score is a composite of the weighted regional similarities, penalized by the topological error factor, providing a nuanced measure of anatomical structural preservation.

3. Motion-Compensated Mutual Information (MC-MI)

The Motion-Compensated Mutual Information (MC-MI) component refines the classic information-theoretic metric for the dynamic abdominal environment. The principle behind MC-MI is that traditional MI is easily confounded by physiological motion, often misinterpreting intensity changes caused by the displacement of organs between scans as a loss of shared information. By incorporating knowledge of the respiratory cycle, MC-MI computes similarity in a motion-corrected space, yielding a purer measure of true information retention between the modalities.

Calculating MC-MI requires access to time-resolved motion data, ideally from a 4D CT or respiratory-gated MRI acquired in the same session as the static scans. This data provides a time-varying motion field, $\Phi_{\text{motion}(t)}$, that models the respiratory-induced deformation. The first step is to temporally phase-match the static CT and MRI scans to determine their respective points in the respiratory cycle. The key innovation follows: before constructing the joint histogram for the MI calculation, the intensity values from the moving image are sampled using a transformation that incorporates both the spatial registration field Φ_{reg} and the compensatory motion field $\Phi_{\text{motion}(t)}$. This crucial step realigns the intensity pairs from the two modalities as if they were acquired at the same respiratory phase, effectively removing the motion artifact that corrupts the standard MI calculation.

The MAFQI synthesizes these three sophisticated components into a single, comprehensive, and clinically actionable score. It introduces several paradigm-shifting innovations that address the core limitations of traditional metrics. Its primary advancement is the first-ever integration of biomechanical modelling into quality assessment, moving the evaluation from mere pixel-level statistics to a physics-informed simulation that predicts tissue deformation, thereby offering a more realistic ground truth for a dynamic environment.

Conclusion

While traditional metrics remain useful for initial fusion evaluation, they fall short in capturing the clinical and physiological realism required in abdominal MRI-CT fusion. The proposed MAFQI offers a novel, hypothesis-driven framework that incorporates biomechanical plausibility, anatomical preservation, and motion compen-

sation. Future work will involve validation on clinical datasets, optimization of weighting parameters, and integration with deep learning fusion models. This approach may set a new standard for evaluating multi-modal abdominal image fusion, ultimately improving diagnostic accuracy and treatment planning.

References

1. Nie X. Multi-Modal Image Fusion for Medical Diagnosis: Combining MRI And CT Using Deep Generative Models / X. Nie // Computer and Medical Health Research Journal. — 2025. — Vol. 5, No. 3. — P. 1313–1327.
2. Jajoo A., Musande V.B. Deep Learning-Driven Multi-Modality Image Fusion: Enhancing MRI and CT Registration and Diagnostic Performance / A. Jajoo, V.B. Musande // Advances in Nonlinear Variational Inequalities. — 2024. — Vol. 28, Issue 3s.
3. Liu Y., et al. CT and MRI Image Fusion using Wavelet Transform and Log Gabor filter / Y. Liu, et al. // BioRes Scientia. — 2024.
4. Kumar S., et al. A Review of Deep Learning-based Multi-modal Medical Image Fusion / S. Kumar, et al. // Open Bioinformatics Journal. — 2025. — Vol. 18.
5. Chen H., et al. CT-3D MERGE fusion imaging improves image quality compared to CT or MRI alone in lumbar spine imaging / H. Chen, et al. // [Electronic resource]. — 2024. — Access mode: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11671808/> (date accessed: 15.08.2025).
6. Zhang J., et al. Medical image fusion model using CT and MRI images based on deep learning / J. Zhang, et al. // ScienceDirect [Electronic resource]. — 2025. — Access mode: <https://www.sciencedirect.com/science/article/abs/pii/S1746809425004434> (date accessed: 25.08.2025).

ПРОГНОЗИРОВАНИЕ БИОТИЧЕСКИХ ВРЕМЕННЫХ РЯДОВ С УЧЁТОМ ВНЕШНЕГО ФАКТОРА

Б.В.Олейников¹, А.В.Пакулев¹

¹Сибирский федеральный университет,

Институт математики и фундаментальной информатики, базовая кафедра вычислительных и информационных технологий, oleynik4810@gmail.com

Как отмечает в своей докторской диссертации А.А. Максимов, исследование поведения биоты, поиск закономерностей её развития, включая многолетнюю динамику численности и биомассы организмов, входящих в ту или иную биоту, «представляет собой одну из важнейших и, пожалуй, самых трудных задач экологии» [1]. Особая роль в выявлении таких закономерностей отводится водной биоте, представители которой, по общепризнанному мнению, являются важнейшими индикаторами природной среды. Интерес к этим исследованиям в последние годы значительно усилился в связи с обсуждением последствий глобального потепления климата, грядущего вследствие, как полагают многие исследователи, хозяйственной деятельности человека. Проводимые исследования по межгодовым колебаниям основных характеристик той или иной биоты (численность, биомасса организмов) позволили накопить достаточно большое количество соответствующих данных, однако, несмотря на это «единого мнения о причинах таких колебаний до сих пор нет» [1]. Определяющими причинами этого, по всей видимости, является то, что изменение характеристик биоты с течением времени может быть обусловлено многими факторами, осуществляющими комплексное воздействие на её состояние: влияние внешних глобальных факторов (солнечная активность, общегалактическое излучение, приливные силы, общее состояние планеты), изменение локальных климатических и гидрологических условий (температура, водность и т.п.), антропогенное воздействие, связанное с привнесением вредных для биологических сообществ веществ, наличие конкурентных, трофических взаимодействий и др. Учитывая комплексный характер этих факторов и отсутствие каких-либо теоретических предпосылок долгосрочной изменчивости отследить влияние каждого из них, а также всего ком-

плекса факторов на состояние того или иного биологического вида, или сообщества в целом несмотря на предпринятые попытки, по признанию исследователей, оказалось невозможным - «всё может влиять на всё» [1].

В настоящих тезисах отражена попытка учёта влияния внешнего глобального фактора в виде солнечной активности при выявлении изменчивости биоты, представленной населением донных сообществ, - бентосом Красноярского водохранилища, дающая возможность и адекватного подхода к восстановлению пропущенных значений в биотических временных рядах.

Бентос (зообентос, макрозообентос) играет большую роль в любом водоеме, не только как кормовая база для ихтиофауны, но и, прежде всего, как фильтр воды, обеспечивающий ее надлежащее качество. Из всех обитателей водоёма бентос считается наиболее эффективным индикатором водной природной среды. Поэтому в настоящее время состояние бентоса (видовой состав, количество особей, их биомасса, удельные показатели) выступает одним из основных биологических индикаторов на основе которого рассчитываются различные коэффициенты качества воды, например, индекс Вудивисса.

Изучение бентоса Красноярского водохранилища с 1974 по 2005 годы регулярно проводилось на кафедре гидробиологии Красноярского государственного университета под руководством зав. кафедрой профессора Гольд З.Г. Накоплено значительное количество данных. Результаты этих исследований обобщены в коллективной монографии [2]. В ряду многих причин затрудняющих детальные исследования состояния бентоса и прогнозирование его характеристик, основной, прежде всего, является некомплектность исходных данных, обусловленная несовершенством используемых орудий взятия проб, методик определения их характеристик, нарушением регулярности взятия проб, связанной с погодными, экономическими и другими условиями. Как следствие, погрешность только по видовому составу в отобранных пробах может достигать 50 %, верифицируемая повторностью проб [3]. Отсюда, все рабочие таблицы объект-признак являются таблицами с большой степенью некомплектности – см. Рис. 1.

станция код вида	1					3					5					15					18					24					26					29					31					35				
	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5					
1010201																																																		
1010801																																																		
1011102																																																		
1011105																																																		
1020201																																																		
1020300																																																		
1020301																																																		
1020601																																																		
4010101																																																		
4010301																																																		
4010701																																																		
4011001																																																		
4011601																																																		
4011602																																																		
4011904																																																		
4013100																																																		

Рис.1 Часть таблицы с пропусками. Здесь по вертикали указаны коды видов организмов (в кодировке 1995 г.), а по горизонтали номера станций, на которых отбирались пробы в 1978-1983 гг. (по порядку) на Красноярском водохранилище. Не закрашенная клетка – отсутствие вида.

Как следствие, временные ряды даже после предобработки содержат пропуски в данных. Поэтому одной из первостепенных задач является восстановление комплектности данных. При восстановлении комплектности биотических временных рядов следует обратить внимание на то, что пропуски в данных могут быть двоякого рода: отсутствие данных по объективным причинам, вызванным условиями среды обитания (пропуски 1-го рода) и отсутствие вследствие неполноты данных, связанной с условиями и орудиями отбора проб, их обработкой и анализом (пропуски 2-го рода). Пропуски 1-го рода — это проблема гидробиологов, пропуски 2-го рода — проблема математиков. Предварительный анализ таблиц в большинстве случаев позволяет предположить второе.

При решении поставленных задач основное внимание в работе было уделено следующим моментам в восстановлении пропусков и прогнозировании биотического временного ряда

- 1) Определение глобального фактора и его полнокомплектного временного ряда
- 2) Определение соразмерного по отклику видового сообщества, отражающего влияние внешнего фактора.
- 3) В случае наличия такого сообщества и соответствующего временного ряда, имеющего в том числе и пропуски в данных, можно объединить, сопоставляя по датам, полнокомплектный временной ряд внешнего фактора и соответствующий некомплектный биотический ряд в единый многомерный (в частности, двумерный) временной ряд фактор – биота. Далее на основе подхода скользящего окна применить методы прогнозирования временных рядов для восстановления (вменения) пропущенных данных и прогнозирования.

При таком подходе полнокомплектный временной ряд является как бы «реперным» и косвенно способствует достоверному прогнозированию биотического ряда. Использование скользящего окна позволяет не только экстраполировать временные ряды, привлекая известные методы, но и вычислять промежуточные значения (интерполировать), используя части ряда, что может быть широко использовано при работе с данными, содержащими пропуски (косвенное вменение данных).

Следуя Чижевскому А.Л. [4] в качестве внешнего глобального фактора рассмотрена солнечная активность, выраженная в числах Вольфа. Данные взяты в [5].

В качестве объекта отклика рассмотрены последовательно 3 группы объектов, представленные во всём водоёме (по всем станциям отбора проб) своей общей биомассой (продуктивностью): наиболее встречаемый вид, наиболее представительная группа сапробности, всё донное население водоёма. В результате препроцессинга исходных данных, включающего усреднение по повторностям проб и сезонности, нормализацию и стандартизацию данных выяснилось, что наиболее соответствующий отклик внешнему глобальному фактору (солнечной активности) среди рассмотренных групп донных сообществ даёт всё донное

население, определяющее продуктивность (по биомассе) всего водоёма. В этом случае как бы проявляется эффект эмерджентности (термин ввел Карл Людвиг фон Бергаланфи, биолог, основатель общей теории систем) – возникновение в системе новых интегративных качеств, которые нельзя получить рассматривая отдельные ее компоненты. Весь водоём выступает как единый организм, в котором нивелированы характеристики отдельных участков биотопа и все внутренние связи биоты, и поэтому более выпукло проявляется отклик на внешнее глобальное воздействие – см. Рис. 2.




Рис.2 Нормированные временные ряды чисел Вольфа и биомассы
всего бентосного сообщества Красноярского водохранилища. Разрывы
линий – пропуски в данных

В настоящее время для прогнозирования временных рядов разработано достаточно много методов, включая классические методы экспоненциального сглаживания, методы, связанные с факторизацией данных, разнообразные нейронные сети. В настоящей работе для осуществления прогнозирования рассмотренных бентосных временных рядов были использованы сверточная (CNN) и рекуррентная (RNN) нейронные сети [6], а также метод тройного экспоненциального сглаживания Хольта-Винтерса [7] на основе подхода скользящего окна. Для первоначального заполнения пропусков и последующего сравнения получа-

емых результатов восстановления значений временного ряда также использовался метод EM SVD [8].

Первоначальное обучение указанных сетей и настройка методов для подтверждения возможности использования их для прогнозирования биотических временных рядов была проведена на временном ряде чисел Вольфа, (см. Рис.3).




Рис. 3 Прогноз чисел Вольфа (нормированный вид), на период 2023–2040 гг.

Для оценки качества моделей прогнозирования использовались метрики: MSE (Mean Squared Error), R^2 (Coefficient Determination), MAE (Mean Absolute Error), а также диаграммы рассеивания [9].

Реализация предобработки, рассмотренных методов и нейронных сетей проводилась на языке программирования Python с использованием библиотек Keras, Tensorflow, Scikit-learn. Были проведены многочисленные эксперименты по настройке параметров нейронных сетей и метода Хольта-Винтерса.

Полученные результаты показали:

1. CNN и RNN, при правильной настройке, достаточно хорошо предсказывают значения временных рядов, в сравнении с методом Хольта-Винтерса, имеющим почти в 2 раза большую среднеквадратичную ошибку предсказания.

2. RNN более чувствительна к локальным минимумам, в то время как CNN лучше определяет максимум.
3. Обе сети значительно хуже предсказывают резко сниженные минимальные значения, но в этом плане почти также ведет себя и метод Хольта-Винтерса.

При использовании EM SVD для первоначального заполнения пропусков требуется, чтобы исходные данные были представлены в виде матрицы. В нашем случае, с учетом влияния глобального фактора, мы имеем двумерный временной ряд, одна компонента, которого представляет числа Вольфа, а другая – биомассу бентоса всего водоёма в исследуемый период (1974 – 2005). Для представления этого двумерного ряда в виде двумерного массива проводится его автосегментация через равные промежутки времени, суммарные значения которых соответствует периоду исследования (1974 – 2005 гг.). Учитывая длину исследуемого периода (32 года), весь исходный двумерный ряд разбивается на 4 равные части и из них формируем двумерный массив, размерности 8x8, где нечётные строки – числа Вольфа за период соответствующего сегмента, а чётные - значения биомассы бентоса за тот же период. Далее применяется стандартная процедура EM SVD, которая даёт полностью заполненную матрицу. После этого соответствующие строки полученной матрицы вновь рассматриваются как сегменты, из соответствующей последовательности которых вновь формируются временные ряды для влияющего фактора (солнечная активность) и объекта отклика (биомасса всего водоёма). Полученные ряды, далее сравниваются с исходными на предмет проверки качества восстановления (прогнозирования).

На Рис.4 представлены прогнозные значения для пропущенных данных во временном ряде биомасса бентоса во всём водоёме, полученные разными методами.




Рис.4 Прогнозные значения пропусков во временном ряде биомасса бентоса во всём водоёме.

В качестве заключения:

- Для рассмотренных бентосных временных рядов с учётом внешнего глобального фактора в виде солнечной активности свёрточные нейронные сети (CNN) дают лучший результат прогнозирования значений на небольшом наборе данных, в сравнении с рекуррентными нейронными сетями (RNN) и методом Хольта-Винтерса. Похожий результат даёт и EM SVD.
- Чтобы увеличить точность заполнения пропущенных значений RNN требуется значительное увеличение данных для обучения.
- Сравнение предсказанных значений биомассы бентоса по наиболее встречающемуся отдельному виду, наиболее представительной группе сапробности и всему водохранилищу в целом говорит о том, что в условиях локализованного природного биотопа прогнозирование состояния донных сообществ должно опираться на более широкий охват населения донного сообщества, обеспечивающий более представительную общую характеристику сообщества, которая позволяет более чётко отслеживать влияние внешнего фактора.
- В дальнейшем, отталкиваясь от полученных результатов прогнозирования на уровне всего водоёма, можно пытаться осуществлять прогнозирование

на более низких уровнях общности организмов.

- Для верификации подхода и представленных результатов необходимо провести аналогичные исследования на биотических временных рядах (желательно более длинных) других объектов.

Список литературы

1. Максимов А.А. Закономерности межгодовой и многолетней динамики макрозообентоса (на примере вершины Финского залива), 2018. Автореф. докт. дисс. / <https://www.zin.ru/boards/24.1.026.02/materials/MaximovAA.pdf>
2. Красноярское водохранилище: биота, качество вод: монография / под. ред. акад. А.Ф.Алимова, д-ра биол. наук М.Б.Ивановой; отв. за выпуск проф. З.Г.Гольд – Красноярск: Сибирский федеральный ун-т, 2008. – 537 с.
3. Олейников Б.В. Развитие автоматизации информационно-математического обеспечения гидробиологических исследований Красноярского водохранилища // Красноярское водохранилище: биота, качество вод: монография, гл.6 / под. ред. акад. А.Ф.Алимова, д-ра биол. наук М.Б.Ивановой; отв. за выпуск проф. З.Г.Гольд – Красноярск: Сибирский федеральный ун-т, 2008. – С. 473-506\
4. Чижевский А.Л. Земное эхо солнечных бурь. / А. Л. Чижевский; научный редактор С. Н. Кумкес. – Москва: Мысль, 1976. – 367с.
5. World Data Center for Solar-Terrestrial Physics. / <http://www.wdcb.ru/stp/solar/sunspots.html>
6. Сверточные и рекуррентные нейронные сети. / <https://moodle.kstu.ru>
7. Семененко М.Г., Унтилова Л.А. Модель Хольта –Уинтерса: математические аспекты и компьютерная реализация // Вектор науки ТГУ. Серия: Экономика и управление. – 2016.– № 3 (26) - С.64-67
8. Zhang Sh., Wang W., Ford J., Makedon F. Using singular value decomposition approximation for collaborative filtering // Proceedings of the Seventh IEEE International Conference on E-Commerce Technology (CEC'05) - 2005 IEEE. - 1-8 p. / : <https://www.researchgate.net/publication/4182299>
9. Метрики оценки качества моделей и анализ ошибок в машинном обучении. Подробное руководство. / <https://habr.com/ru/articles/821547/>

МЕТОД НЕКОНТРОЛИРУЕМОГО СОЗДАНИЯ ПОДПИСИ К ИЗОБРАЖЕНИЮ ДЛЯ ЗАДАЧИ ПОВТОРНОЙ ИДЕНТИФИКАЦИИ ЧЕЛОВЕКА

М.В.Савков¹

¹Сибирский государственный университет
науки и технологий имени академика М.Ф. Решетнева,
Институт информатики и телекоммуникаций, *msavkov2017@gmail.com*

Проблема повторной идентификации человека возникает в таких областях, как видеонаблюдение, анализ поведения людей и безопасность. Методы, необходимые для решения данной проблемы, зависят от краткосрочного или долгосрочного наблюдения, что также влияет на стратегию обучения. Краткосрочное наблюдение означает, что запись о конкретном человеке может отсутствовать в базе данных. Человек, которого необходимо повторно идентифицировать, может появиться в любом месте в разные моменты времени и может быть зафиксирован разными камерами. В таком случае информация о человеке должна собираться и обрабатываться в реальном времени. Информация об интересующем человеке может быть представлена изображением, видеопоследовательностью или текстовым описанием. В данном исследовании мы предполагаем, что входной информацией является изображение.

Мы заинтересованы в разработке стратегии неконтролируемого обучения (обучение без учителя), которая будет применима для повторной идентификации человека в толпе с возможным перекрытием визуальных проекций. Это сложная задача, требующая использование всех возможных семантических подсказок, атрибутов и различных модальностей. Недавние достижения в сфере глубоких языковых моделей привели к появлению идеи «изображение-текст» в задачах повторной идентификации человека. Модель визуального языка кодирует изображения для получения признаков, а затем генерирует текстовое описание, которое поясняет контекстную информацию на изображении.

Первые модели повторной идентификации человека на основе сверточных нейронных сетей, такие как OSNet [1], были ограничены обучающими данными и были склонны к переобучению. Модель AANet [2] объединила ключевые атрибуты, такие как цвет верхней одежды, волосы, пол и другие в единую систему обучения с использованием дискриминационных карт атрибутов на уровне изображения. Последовательная пакетная сеть [3] обеспечивает эффективную стратегию обучения механизма внимания для извлечения глобальных и локальных признаков. В другой работе [4] был предложен метод контрфактического обучения механизма внимания путем внедрения причинно-следственных выводов для улучшения качества. В последнее время модели на основе трансформеров, такие как сквозной трансформер с учетом частей [5] и сеть обучения с распутанным представлением [6] используют сильные стороны как сверточных нейронных сетей, так и трансформеров для дальнейшего улучшения производительности моделей.

На данный момент мультимодальные подходы, объединяющие визуальные и текстовые данные, стали очень популярны в задачах повторной идентификации человека. Модель CLIP (Contrastive Language-Image Pre-training) [7] представляет изображение и текст в общее пространство, что позволяет модели сопоставлять признаки двух модальностей, однако она имеет ряд ограничений, связанных с извлечением контекстно-специфических деталей и необходимостью обеспечения качества и релевантности пар «изображение-текст» в процессе обучения.

Визуальное представление человека характеризуется ограниченными, небольшими по размеру визуальными признаками с различными цветами и предсказуемыми связями. Это означает, что визуально-текстовый дескриптор, основанный на модели CLIP, имеет меньший размер чем базовая модель. Еще одно предложение – использовать сегментацию экземпляров для получения визуальной проекции человека, что значительно повышает точность распознавания. Мы протестировали предложенный метод на изображениях людей, отобранных из набора данных MSCOCO, продемонстрировав его эффективность и способность к обобщению.

Преобразование репрезентативных характеристик изображения в описание может быть выполнено разными методами. В ранних моделях создания описания наблюдался разрыв между локальным контекстом и структурной информацией, когда в качестве условных элементов языка использовались высокоуровневые представления последних слоев сверточных нейронных сетей. Другим подходом является использование дополнительного распределения вероятностей общих слов. Более подходящим способом является использование неразмеченных данных, когда для каждого изображения генерируется псевдоподпись для инициализации модели создания подписей к изображениям по псевдопарам «изображение-предложение», как например в работе [8].

Простота и компактность представления глобальных признаков являются основными преимуществами модели создания подписей к изображениям на основе сверточных нейронных сетей. Однако конкретные и тонкие описания являются источниками подробной контекстуальной информации, которую можно извлечь с помощью механизма внимания или графовой модели. Мы упростили общую задачу создания подписей к изображениям, добавив модуль сегментации экземпляров в качестве внешнего модуля к модели создания подписей к изображениям. На основе наших предыдущих экспериментов [9] был выбран неконтролируемый двухэтапный детектор CutLER [10]. Таким образом, наша модель создания подписей к изображениям близка к модели создания подписей к изображениям без учителя, разработанной в работе [8].

Большинство моделей повторной идентификации человека обрабатывают изображения, содержащие значительную фоновую информацию, которая может вносить шум в представления признаков. Чтобы снизить влияние этого фактора, мы применили детектор CutLER для выполнения неконтролируемой сегментации экземпляров, обеспечивающей сохранение только человека на переднем плане. Работа CutLER состоит из трех этапов: создание нескольких начальных грубых масок для изображения с помощью модуля MaskCut, обучение детекторов на основе грубых масок (с использованием условных случайных полей для сглаживания границ объектов и удаления мелких артефактов фона) и создание

окончательной маски. Для лучшего извлечения визуальных признаков мы дополнительно очищаем фон с помощью обнаруженной маски.

Хотя использование модели CutLER значительно уменьшает количество фоновых шумов и улучшает четкость извлечения визуальных признаков, оно также вводит зависимость от качества масок экземпляров. Неточная сегментация может привести к частичной окклюзии или усечению фигуры человека, что, в свою очередь, негативно сказывается на генерации текста.

Входными данными для создания подписей к изображениям являются реальные изображения людей и корпус соответствующих предложений, описывающих человека, в качестве подсказок для неконтролируемого обучения генератора текста. Визуальные и текстовые данные не коррелируют друг с другом. Кодировщик изображений на основе сверточной нейронной сети часто строится на моделях Inception-ResNet-v4 или ResNet-50. В данном случае мы использовали модель R2-Inception-V4.

Генератор текста на основе LSTM включает 10 ячеек LSTM (long short-term memory) и пытается описать содержимое изображения в виде естественного предложения. Каждая ячейка LSTM выдает распределение вероятности, по всем словам, в словаре и ранее сгенерированным словам. LSTM использует три типа затворов: входные, забывающие и выходные, чтобы обеспечить хранение и обновление контекстной информации в долгосрочных зависимых задачах. Эти три затвора используются для управления тем, нужно ли забыть текущее значение ячейки, нужно ли считать входные данные и нужно ли вывести новое значение ячейки.

Поскольку данные о парных изображениях и предложениях недоступны, объективными функциями, позволяющими осуществлять неконтролируемое создание подписей к изображениям, являются специальные вознаграждения, а именно вознаграждение за состоятельность, вознаграждение за концепцию и вознаграждение за восстановление изображения. Увеличение значения состоятельного вознаграждения означает, что генератор постепенно учится генерировать правдоподобные предложения, следуя правилам грамматики. Однако сгене-

рированные таким образом правдоподобные предложения могут не соответствовать входному изображению. Подписи к изображениям становятся релевантными, когда модель подписей включает визуальные понятия в генерируемое предложение. Для этого вводится вознаграждение за концепцию, которое оценивается по шкале доверия к данной визуальной концепции. Поскольку детекторы визуальных концептов могут надежно обнаружить ограниченное число концептов объектов, третий тип вознаграждения - вознаграждение за реконструкцию изображения - играет роль оценщика объективной способности к обобщению. Однако, поскольку методы реконструкции изображений по предложениям недостаточно разработаны, целесообразно оценивать не реконструированное изображение, а его признаки. Объективная функция реконструкции предложений определяется как потеря кросс-энтропии.

В отличие от оригинальной модели неконтролируемого составления подписей к изображениям, которая использует детекторы объектов и внешние наборы данных подписей, наш метод вводит явный шаг сегментации экземпляра с помощью CutLER. В отличие от предыдущих подходов, которые полагаются на предложения фиксированных областей или визуальный контекст на основе сцены, наш метод гарантирует, что для создания титров используется только форма человека. Это предположение приводит к созданию более релевантных и точных текстовых описаний, особенно подходящих для задачи повторной идентификации человека, где визуальный контекст за пределами человека может вносить шум.

Для эксперимента мы выбрали набор данных MSCOCO (Microsoft Common Objects in Context) [11] как один из самых распространенных и разнообразных наборов данных, используемых для обучения и оценки систем компьютерного зрения. В полной версии он содержит более 200 тысяч изображений (из которых около 118 тысяч выделено для обучающей выборки, 5 тысяч - для валидационной и еще 5 тысяч - для тестовой). Кроме того, MSCOCO примечателен тем, что сцены в нем максимально приближены к повседневным (кухонная утварь, люди, уличные сцены, животные и т. д.). Развитое тематическое и визу-

альное разнообразие помогает моделям, обученным на COCO, лучше обобщаться на реальные условия. Кроме того, в качестве текстового корпуса мы будем использовать большую коллекцию описаний, собранную на Shutterstock, чтобы обучить модель генерировать подробные фразы на основе визуальных признаков.



Рис. Примеры изображений MSCOCO и текстовых аннотаций: а - исходные изображения, б - сгенерированные текстовые аннотации без использования CutLER, в - сегментированные изображения с использованием CutLER, г - сгенерированные текстовые аннотации с использованием CutLER.

Для предварительного обучения предложенной модели необходимо аннотировать ряд изображений из набора данных. Аннотации были сделаны для 11% набора данных. Обучение модели создания подписей к изображениям проводилось с помощью неконтролируемой процедуры, аналогичной схеме, описанной в работе [8]. Псевдоподписи инициализировались с помощью корпуса текстовых описаний одежды, цветов и внешности человека. Обучение проводилось в течение 40 эпох. Модель была оптимизирована с помощью комбинации из потери при состязании, оценки распознавания понятий и вознаграждения за реконструкцию признаков. Псевдоподписи генерировались путем проецирования вкраплений изображений в общее латентное пространство и декодирования их с

помощью генератора на основе LSTM, обученного на внешнем корпусе.

Задача повторной идентификации человека требует аннотации одежды и цвета. Были выбраны 3 типа одежды выше талии и 3 типа одежды ниже талии. Примером аннотации могут служить такие фразы, как: «Мужчина в синем пиджаке и черных брюках», «Женщина в белой футболке и серых шортах» и так далее. На рисунке показаны примеры исходного и сегментированного изображений и сгенерированных текстовых аннотаций.

Для оценки качества сгенерированных текстовых описаний были выбраны пять метрик: BLEU, METEOR, ROUGE, CIDEr и SPICE. Двухязычная оценка понимания (BLEU) - одна из самых ранних и широко используемых метрик для оценки качества машинного перевода и автоматически созданных описаний [12]. BLEU основана на сравнении n-грамм результата с одним или несколькими эталонными текстами; чем выше совпадение, тем лучше модель сохраняет контекст и словарный запас. Различные варианты BLEU отражают глубину анализа: BLEU-1 (униграммы) показывает степень совпадения отдельных слов, но не учитывает их последовательность. Более высокие порядки n-грамм, такие как BLEU-2, BLEU-3 и BLEU-4, уже позволяют судить о правильности формирования фраз и учитывают структуру предложения, поскольку проверяют совпадения биграмм, триграмм и тетраграмм соответственно.

Метрика оценки перевода с явным упорядочиванием (METEOR) расширяет анализ за счет учета синонимов, морфологических форм и порядка слов, что делает его более чувствительным к лексическим и грамматическим особенностям текста [13].

Recall-Oriented Understanding for Gisting Evaluation (ROUGE) — это набор метрик, чаще всего включающий ROUGE-N и ROUGE-L, ориентированных на измерение полноты (recall) [14]. Они оценивают степень совпадения n-грамм или самой длинной общей последовательности с эталонным описанием, что первоначально сделало ROUGE особенно полезным в задаче автоматического реферирования текста, но позже нашло широкое применение в оценке систем создания подписей к изображениям.

Другая важная метрика, оценка описания изображений на основе консенсуса (CIDEr), используется в основном для оценки качества визуальных описаний [15]. Она опирается на TF-IDF-представление n-грамм, сопоставляя полученную подпись сразу с несколькими эталонными, и поощряет согласованность терминов. Наконец, Semantic Propositional Image Caption Evaluation (SPICE) нацелена на проверку семантических связей: метрика строит граф сцены и сравнивает объекты, атрибуты и связи в сгенерированном описании с теми же элементами в эталонном [16].

Таким образом, каждая из перечисленных метрик оценивает определенные аспекты качества сгенерированных текстов, дополняя друг друга и обеспечивая комплексную проверку соответствия автоматических описаний эталонным. В таблице приведены усредненные значения точности для выбранных изображений MSCOCO с использованием и без использования CutLER. Здесь B1, B2, B3 и B4 - метрики BLEU-1, BLEU-2, BLEU-3 и BLEU-4.

Таблица

Таблица усредненных значений точности для выбранных изображений

MSCOCO с и без CutLER

Метод	B1	B2	B3	B4	METE- OR	ROUG E	CI- DEr	SPICE
Без Cut- LER	41,0	22,5	11,2	5,6	12,4	28,7	28,6	8,1
С CutLER	41,6	23,8	11,9	5,8	13,2	30,3	28,9	8,1

Из таблицы видно, что при добавлении CutLER (модуля автоматической сегментации переднего плана) все текстовые метрики (BLEU1-BLEU4, METEOR, ROUGE-L, CIDEr и SPICE) становятся выше. Основная причина заключается в том, что, обрезая фон, модель создания титров анализирует только фигуру человека и лучше выделяет соответствующие атрибуты (цвет одежды, аксессуары и т. д.). В результате описания получаются более точными и последовательными, что отражается на улучшении производительности.

Таким образом, предложенный метод, сочетающий неконтролируемую сегментацию с генерацией текстовых описаний, демонстрирует улучшение каче-

ства автоматических подписей к изображениям в эксперименте на наборе данных MSCOCO. Включение этапа выделения целевых объектов значительно снижает влияние фоновых областей и способствует более точному выделению ключевых визуальных характеристик сцены. Это отражается в повышении эффективности метрик BLEU, METEOR, ROUGE-L, CIDEr и SPICE по сравнению с моделью без сегментации, что свидетельствует об эффективности предложенного подхода в формировании подробных и последовательных описаний в отсутствие аннотированных пар «изображение-текст».

Несмотря на улучшения, полученные с помощью сегментации и обучения без учителя, зависимость модели от качества сегментации и отсутствие точного выравнивания текста и изображения остаются проблемами. Дальнейшие усовершенствования могут включать в себя включение механизмов уточнения на основе внимания или самоконтролируемую тонкую настройку визуальных вкраплений для повышения устойчивости к различным сценам.

Список литературы

1. Zhou K. Omni-scale feature learning for person re-identification / K.Zhou, Y.Yang, T. Xiang. — 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Republic of Korea, 2019. — 3702 – 3712 p.
2. Tay C.P. Attribute attention network for person re-identifications / C.P.Tay, S.Yap. — 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019. — 7134 – 7143 p.
3. Tan H. Incomplete descriptor mining with elastic loss for person re-identification / H.Tan, X.Lui, Y.Bian. — IEEE Trans. Circuits Syst. Video Technol, Long Beach, CA, USA, 2021. — 160 – 171 p.
4. Rao Y. Counterfactual attention learning for fine-grained visual categorization and re-identification / Y.Rao, G.Chen, J.Lu. — 2021 IEEE/CVF International Conference on Computer Vision (ICCV), Montreal, QC, Canada, 2021. — 1025 – 1034 p.
5. Li Y. Diverse part discovery: Occluded person re-identification with part-aware transformer / Y.Li, J.He, T.Zhang, X.Liu. — 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Nashville, TN, USA, 2021. — 2898 – 2907 p.
6. Jia M. Learning disentangled representation implicitly via transformer for occluded

- person re-identification. / M.Jia, X.Cheng. — IEEE Trans. Multimed. 25, Nashville, TN, USA, 2023. — 1294 – 1305 p.
7. Radford A. Learning transferable visual models from natural language supervision / A.Radford, J.Kim. — The 38th International Conference on Machine Learning, Seoul, Republic of Korea, 2021. — 8748 – 8763 p.
 8. Feng Y. Unsupervised image captioning / Y.Feng, L.Ma. — 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2019. — 4125 – 4134 p.
 9. Favorskaya M.N. Study on unsupervised instance segmentation models for person re-identification / M.N.Favorskaya, M.V.Savkov. — XLVIII-2/W5-2024, International Workshop on “Photogrammetric Data Analysis”, Moscow, Russia, 2024. — 41 – 48 p.
 10. Wang X. Cut and learn for unsupervised object detection and instance segmentation / X.Wang, R.Girdhar. — 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, Canada, 2023. — 3124 – 3134 p.
 11. Lin T. Microsoft COCO: Common objects in context / T.Lin, M. Maire. — Computer Vision – ECCV 2014, Vancouver, Canada, 2014. — 740 – 755 p.
 12. Papineni K. BLEU: a method for automatic evaluation of machine translation / K.Papineni, S.Roukos, T.Ward. — 40th Annual Meeting of the Association for Computational Linguistics, Philadelphia, PA, USA, 2002. — 311 – 318 p.
 13. Agarwal A. METEOR, m-bleu and m-ter: Evaluation metrics for high correlation with human rankings of machine translation output / A.Agarwal, A.Lavie. — Third Workshop on Statistical Machine Translation, Columbus, Ohio, USA, 2008. — 115 – 118 p.
 14. Lin C. Rouge: A package for automatic evaluation of summaries / C.Lin. — Text Summarization Branches Out, Barcelona, Spain, 2004. — 74 – 81 p.
 15. Vedentam R. CIDEr: Consensus-based image description evaluation / R.Vedentam, C.Zitnick — 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015. — 4566 – 4575 p.
 16. Anderson P. SPICE: Semantic propositional image caption evaluation / P.Anderson, B.Fernando — Computer Vision – ECCV 2016, Boston, MA, USA, 2016. — 382 – 398 p.

ОБНАРУЖЕНИЕ ЗАМАСКИРОВАННЫХ ОБЪЕКТОВ НА ИЗОБРАЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ ДИФфуЗИОННЫХ МОДЕЛЕЙ НА ОСНОВЕ КАРТ НЕОПРЕДЕЛЁННОСТИ

Н.В.Саидов¹

¹Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева, Институт информатики и телекоммуникаций, кафедра информатики и вычислительной техники, *nazar-saidov1999@mail.ru*

Введение. Обнаружение замаскированных объектов (Camouflaged Object Detection, COD) является одной из наиболее сложных задач компьютерного зрения. В отличие от традиционной сегментации, где объекты чётко отделяются от фона, при COD целевые объекты маскируются в окружающей среде благодаря схожести текстур, цвета и формы. Это приводит к тому, что алгоритмы, основанные на классической сегментации, часто допускают ошибки на границах объектов и демонстрируют низкую устойчивость к сложным сценам.

Актуальность задачи COD обусловлена широким спектром её приложений. Она востребована в военной сфере, где обнаружение замаскированных объектов напрямую связано с безопасностью, в биологии – для выявления цветовой мимикрии, в медицине – при сегментации сложных структур на изображениях. Универсальность задачи делает её особенно важной для развития методов компьютерного зрения.

Недавние исследования показали, что диффузионные модели могут существенно улучшить качество сегментации благодаря способности к моделированию распределений и генерации различных вариантов масок. Однако в условиях высокой неопределённости, например, на размытых или шумных границах, даже диффузионные модели склонны выдавать так называемые преувеличенные ошибки (overconfident mispredictions), когда модель делает крайне уверенное, но неправильное предсказание.

В связи с этим, предлагается современный подход, основанный на интеграции диффузионных моделей и оценки неопределённости. Такой подход поз-

воляет направлять процесс восстановления (denoising), обеспечивая точные предсказания даже в областях с высокой неопределённостью.

Обзор методов. Подходы к обнаружению замаскированных объектов варьируются – от классических методов, не основанных на нейросетях, до современных вероятностных генеративных схем. В этой работе мы разграничиваем их по источникам априорной информации и по степени приспособленности к слабоконтрастным границам. Так, например, ряд сцен с умеренной маскировкой позволяет выделять контуры без применения нейросетей. Обычно это сцены, в которых границы объекта достаточно точно определены, хотя этот объект может иметь сходные с фоном текстурные и цветовые признаки. В таких случаях часто применяется вейвлет-анализ. Дискретное вейвлет-преобразование и другие традиционные методы обнаружения выделяют резкие переходы интенсивности и текстурные изломы, а комбинация пороговой обработки коэффициентов и морфологии уже даёт грубые карты объектов. Эти методы просты, воспроизводимы и вычислительно экономичны. На сценах с умеренным контрастом и «чистым» фоном вейвлеты способны уверенно реконструировать границы объекта. Однако при сильной мимикрии, сложном фоне и слабой текстурной разнице их предположения (резкие границы, локальные контрастные признаки) нарушаются, что приводит к заметным искажениям маски. Рассмотрим примеры двух изображений с маскирующимися объектами и применим к ним дискретное вейвлет-преобразование. Таким образом, на Рис.1А видим объект, который хоть и сливается с фоном, однако имеет явно выраженные границы, поэтому хорошо поддаётся сегментации. Однако, если объект имеет нечёткий контур и сильно сливается с фоном, то обычное вейвлет-преобразование не даёт хороших результатов. Так на Рис.1Б представлено изображение со сложной структурой и нечёткими контурами объекта интереса.




Рис.1. Результат обнаружения цветовой мимикрии у объектов:

А-Б) исходные изображения, В-Г) полученные маски

Можем заметить, что в результате применения дискретного вейвлет-преобразования – маска замаскированного объекта с чёткими границами построена достаточно точно (Рис.1В), однако для объекта с нечёткими границами – маска не была сформирована корректно (Рис.1Г), что показывает несовершенство традиционных методов обнаружения в сложных сценах.

С появлением глубокого обучения задачу COD стали решать в парадигме «энкодер-декодер». Энкодеры извлекают многоуровневые признаки, декодеры восстанавливают пространственное разрешение и выдают маску. Для COD часто вводят модули усиления границ, которые фокусируются на «тонких» различиях между объектом и фоном [1]. Иногда вводят энкодеры-трансформеры, что улучшает глобальную согласованность предсказаний: модель лучше отделяет объект на неоднородном фоне. Проблема этих подходов состоит в том, что в областях низкого сигнала изображения (LL-компоненты) визуально объект «растворён» в

фоне, и модель фиксирует одну версию маски, игнорируя альтернативы. Это значит, что если объектов будет несколько, то они не будут корректно определены.

Наиболее перспективным направлением стали диффузионные модели. Они стохастически добавляют шум к данным и обучаются обратному процессу восстановления, что позволяет моделировать сложные распределения и выдавать несколько возможных предсказаний. Однако базовая диффузионная сегментация обучает сеть восстанавливать маску из зашумлённой версии, но склонна терять тонкие границы и «размывать» контуры в самых сложных местах [2].

Предлагается модернизировать стандартный подход с применением диффузионных моделей, который бы помог сместить внимание на наиболее проблемные области.

Предлагаемая методология. В целях улучшения качества сегментации и обнаружения маскирующихся объектов в сложных сценах предлагается усовершенствовать базовый подход с применением диффузионных моделей. Для этого введём карту неопределённости, которая подсказывает, где модель должна перенастраивать динамику восстановления изображения именно на проблемных участках. Ключевая идея состоит в том, что карта неопределённости используется в качестве якорного условия (anchor condition). Она задаёт область, где наиболее вероятны ошибки, и направляет процесс диффузии. Это позволяет сместить внимание модели на проблемные участки, например, на границы объекта. Дополнительно процесс зашумления модифицируется так, что шум добавляется преимущественно в области, отмеченные на карте неопределённости. Таким образом, модель обучается различать реальные детали объекта от фоновых искажений именно там, где стандартные методы демонстрируют наибольшие затруднения. Восстановление изображения при обратной диффузии также проводится с учётом карты неопределённости, что позволяет добиться более точного выделения объектов и их границ.

Пусть у нас имеется некоторое исходное изображение с замаскированным объектом. Стандартная диффузионная модель с распределением прямого диффузионного процесса q на шаге x_t добавляет шум к изображению, который можно

описать по следующей формуле:

$$q(x_t | x_{t-1}) = N(x_{t-1}, \sqrt{1 - \beta_t} x_{t-1}, \beta_t I),$$

где β_t – коэффициент, определяющий уровень шума на каждом шаге, N – нормальное гауссовское распределение, I – единичная матрица (шум добавляется одинаково во все направления в пространстве признаков).

Добавляя шум на каждой итерации, получаем диффузионный процесс, который постепенно намеренно разрушает маску [3].

Предлагается добавлять шум q к истинной маске искомого объекта по формуле:

$$q(x_t | x_0) = N(\bar{\alpha}_t, x_0, (1 - \bar{\alpha}_t) I),$$

где x_0 – истинная маска объекта, x_t – зашумлённая версия на шаге t , N – нормальное гауссовское распределение, I – единичная матрица, α_t – параметр адаптивного управления скоростью добавления шума.

Основным преимуществом является адаптивное управление параметром α [4]. Это позволяет определить гибридный подход к обнаружению объектов в различных сценах.

Обратный процесс восстановления (denoising) описывается через условное распределение p на шаге x_t :

$$p(x_{t-1} | x_t, \hat{x}_0) = N(\mu_t(x_t, \hat{x}_0), \bar{\beta}_t I),$$

где x_0 – истинная маска объекта, β_t – формирует карту неопределённости, исходя из параметров процесса, I – единичная матрица, μ_t – средний очищенный сигнал. Это сочетание даёт баланс между фоном изображения и локальным согласованием границ, что критично для сегментации замаскированных объектов.

На Рис.2А и Рис.2Б представлены результаты применения стандартной диффузионной модели на различных шагах x_t . Видим, что стандартная модель не способна корректно построить маску объекта интереса в сложной сцене, поэтому применим карту неопределённости. Сначала прогнозируется маска по шагам x_t и формируются предварительные контуры (Рис.2В, Рис.2Г). Затем производится диффузионный процесс с учётом карт неопределённости для отделения объекта

от фона и строится итоговая маска (Рис.2Е).




Рис.2. Результат применения диффузии к изображению различными методами: А-Б) стандартная диффузионная модель, В-Г) процесс прогнозирования маски, Д-Е) диффузионная модель с картами неопределённости

Формально оптимизация модели сводится к минимизации функции потерь, которая сочетает стандартный критерий реконструкции маски (например, бинарную кросс-энтропию или L1-норму) с компонентой, учитывающей неопределённость [5]. Последняя служит для того, чтобы «штрафовать» модель сильнее за ошибки в областях высокой неопределённости, тем самым поощряя более осторожное и точное восстановление в таких зонах. Кроме того, при обучении используется механизм агрегирования признаков, управляемый картой неопре-

делённости. Это означает, что признаки разных уровней (от низкоуровневых деталей до глобальных контекстных описаний) не просто объединяются, а перераспределяются так, чтобы модель училась концентрироваться на тех признаках, которые релевантны для выделения замаскированного объекта. Такой механизм усиливает способность модели адаптироваться к разнообразным сценам и улучшает качество сегментации.


Экспериментальная часть. Предложенная методология была протестирована на известных наборах данных для решения задачи COD, а именно на CAMO, COD10K, NC4K [6]. Эксперименты направлены на то, чтобы показать, насколько использование карты неопределённости в сочетании с диффузионным процессом позволяет улучшить сегментацию по сравнению с существующими методами. На Рис.3 приведены несколько изображений с замаскированными объектами, а также маски, полученные в результате применения усовершенствованного метода диффузии.

Для количественной оценки точности сегментации используются общепринятые метрики: MAE – средняя абсолютная ошибка; $F\beta$ – гармоническое среднее точности и полноты; $E\phi$ – учитывает как локальное, так и глобальное согласование между масками; $S\alpha$ – структурная оценка, отражающая соответствие формы объектов [7]. В таблице представлены результаты оценки качества сегментации. Анализируются значения метрик по каждому изображению.

Таблица

Результаты оценки качества сегментации диффузионным методом

Изображения	MAE	$F\beta$	$E\phi$	$S\alpha$
А	0,032	0,858	0,941	0,892
Б	0,029	0,862	0,943	0,895
В	0,063	0,861	0,938	0,892
Г	0,027	0,855	0,942	0,894
Д	0,023	0,860	0,944	0,895



А

Е



Б

Ж



В

З



Г

И



Д

К

Рис.3. Результат сегментации объектов усовершенствованной диффузионной моделью: А-Д) оригинальные изображения, Е-К) полученные маски объектов

Заключение. В работе рассмотрен современный метод обнаружения замаскированных объектов, основанный на интеграции диффузионных моделей и оценки неопределённости. Эксперименты показали высокое качество сегментации замаскированных объектов как по количественным метрикам, так и по визуальной точности. Предложенная карта неопределённости позволяет сосредотачивать вычислительные ресурсы на тех областях изображения, где вероятность ложных предсказаний наиболее высока. Это делает результаты сегментации более надёжными и приближенными к человеческому восприятию. Таким образом, интеграция карт неопределённости в процесс диффузии не только повышает точность и устойчивость модели, но и придаёт ей интерпретируемость, что имеет принципиальное значение для применения в критически важных областях.

Список литературы

1. Fan D. P., Ji G.-P., Sun G., Cheng M.-M., Shao L. Camouflaged object detection // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. — 2020. — P. 2777–2787.
2. Lv T., Liu T., Sun P., Zhang J., Wang C. Simultaneously localize, segment and rank the camouflaged objects // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. — 2021. — P. 11591–11601.
3. Ho J., Jain A., Abbeel P. Denoising diffusion probabilistic models // Advances in Neural Information Processing Systems. — 2020. — Vol. 33. — P. 6840–6851.
4. Song J., Sohl-Dickstein J., Kingma D. P., Kumar A., Ermon S., Poole B. Score-based generative modeling through stochastic differential equations // Proceedings of the International Conference on Learning Representations. — 2021. — 27 p.
5. Lin Z., Ji G.-P., Wu Y., Fan D. P., Cheng M.-M. Frequency-aware camouflaged object detection // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. — 2022. — P. 4526–4537.
6. Kirillov A., Mintun E., Ravi N., Mao H., Rolland C., Gustafson L. et al. Segment Anything // Proceedings of the IEEE/CVF International Conference on Computer Vision. — 2023. — P. 3992–4003.
7. Cheng M. M., Fan D. P. Structure-measure: A new way to evaluate foreground maps // Int. J. Comput. Vis. — 2021. — Vol. 129. — P. 2622–2638.

МЕХАНИЗМЫ РАБОТЫ ИНТЕЛЛЕКТУАЛЬНОЙ АВТОМАТИЗИРОВАННОЙ ОБУЧАЮЩЕЙ СИСТЕМЫ AESU

Г.А. Смирнов¹, А.Д. Пронин¹, М.В. Кузнецов¹, В.А. Углев^{2,1},

¹Сибирский федеральный университет,

²Российский государственный гуманитарный университет,

uglev-v@yandex.ru

Введение

Функциональные возможности автоматизированных обучающих систем, опирающихся на методы искусственного интеллекта, во многом определяются теми концепциями и механизмами, которые лежат в их основе. Фанатичное использование нейронных сетей (например, в [1]) не даёт эффекта объяснимости решений. Использование онтологий (например, в [2]) заставит скрупулезно прорабатывать все варианты решений на уровне каждой учебной задачи. Аналогичным образом обстоит дело со структурным составом интегрированных в интеллектуальные автоматизированные обучающие системы (ИАОС) моделей. Далеко не все системы включают, помимо стандартных моделей ученика и электронного курса [3], модели учителя, тьютора [4] и учебной ситуации [5]. Поэтому от выбранных разработчиками механизмов и моделей будет зависеть гибкость и результативность принятия решений интеллектуальным планировщиком. В некоторых программных решениях эта информация явно декларируется разработчиками и описывается в научной литературе [6,7]. К сожалению, не для каждой ИАОС можно легко найти чётко изложенные данные об лежащих в их основе механизмах и реализованных методах. Поэтому нами было принято решение описать базовые концепции и механизмы ИАОС AESU.

ИАОС AESU была сформирована из ранее созданных программных модулей в виде единой сетевой системы в 2020 году и постепенно приобрела вид экспериментальной LMS с расширенными функциональными возможностями. В её основу легли теории П.К. Анохина о поведенческом акте, прикладная семиотика Д.А. Поспелова, В.А. Лефевра о рефлексивном управлении, когнитивная компь-

ютерная графика А.А. Зенкина. Основными механизмами стали теория продукционных экспертных систем Э. Поста, Нечёткой логики Л. Заде, проверки экспертных мнений Шортлиффа и Бьюкенена, когнитивных карт и пиктографики, а также модульной концентрации данных Г. Смирнова. Дадим их краткую характеристику в контексте использования в ИАОС AESU.

Теории, лежащие в основе ИАОС AESU

Базовые концепции и теории ориентированы на организацию данных и знаний, позволяя обеспечить процесс объяснимого принятия решений. Само принятие решений опирается на модель M , которая для решателя ИАОС является чёрным ящиком и входит в состав модульной базы знаний. Для извлечения и концентрации исходных данных используется *модель афферентного синтеза* из теории функциональных систем П.К. Анохина [8]. Суть её заключается в том, чтобы для принятия решений подготовить исходные данные, включающие описание учебной ситуации (обстановочная афферентация); цифровой образовательный след с прецедентами (имеющийся опыт); номенклатуру событий (пусковую афферентацию); а также работу с целями (акцептор результата). Такая «физиологическая» интерпретация механизма разумного поведения была предложена самим Анохиным в качестве основы для работы интеллектуальных систем [9] и нами лишь адаптирована к специфике ИАОС [10]. Такой массив исходных данных D формирует «поле» признакового пространства, которое должно в дальнейшем подвергаться обработке планировщиком.

Процедура сбора исходных данных не решает проблему её упорядочивания непосредственно для принятия решений. По этой причине декомпозиция включенных в процесс принятия решения данных дополнительно делится на шаблонное представление семантики, синтактики и прагматики, дополненного конкретизированными для текущей учебной ситуации данными (соответствует *квадрату Поспелова* [11] из прикладной семиотики [12]). Роль синтактики (структуры данных) в таком представлении играет модель дидактического материала, иерархии целей и нормативов (тех же компетенций учебного плана). Роль семантики выполняют логические связи между различными элементами (как с

моделями, так и внутри структур данных), а также фрагменты баз знаний. Прагматикой в этом подходе стали модели реакций моделей учащегося, учителя и тьютора (соответствующие фрагменты базы знаний). Непосредственно оперативные данные, их динамика («выжимка» из цифрового образовательного следа) и параметры модели ученика формируют денотат [13]. В результате такого представления все данные после загрузки соотносятся с элементами семиотического представления (размечаются в поле признакового пространства) и могут быть подгружены при обработке события класса k при принятии решений.

Характерной чертой развитых систем искусственного интеллекта, среди прочего, является их способность к рефлексии собственных решений и оперировании расширенной моделью человека, с которым происходит взаимодействие [14]. Эту задачу в своей теории *рефлексивного управления* замечательно формализовал В.А. Лефевр [15]. Мы использовали элементы его подхода не только к обоснованию выделения различных сущностей (модели ученика, учителя, тьютора, методиста), но и различную интерпретацию ими учебной ситуации. Очевидно, что все эти модели имеют не только собственные цели, но и логику оценки важности, нужности, полезности и пр. как различных элементов дидактического материала, так и решений со стороны ИАОС [16]. Кроме того, предложенный подход позволил выделить ряд аспектов анализа (знаниевый, компетентностный, целевой), учёт которых углубляет возможности по анализу учебной ситуации. Так появляются признаки точки зрения на проблему i и аспекта анализа j .

Ещё одна концепция, которую вобрала в себя ИАОС AESU, стала когнитивная визуализация, относимая А.А. Зенкиным и Д.А. Поспеловым к *разделу когнитивной компьютерной графики* [17]. Применительно к обучающим системам Д.А. Поспелов писал следующее: «даже весьма робкие попытки в этом направлении, ... привлекающие сейчас пристальное внимание специалистов (особенно тех, кто занят созданием *интеллектуальных обучающих систем*), показывают перспективность подобных исследований» [18]. Именно эту идею в виде концепции функционально-структурного картирования *Map* мы взяли на во-

оружение как при концентрации данных в процессе принятия решений, так и при предъявлении её человеку-учащемуся. Принцип наглядности и понятности решений за счёт графической концентрации был взят из Data Mining (раздела Data Visualization [19]) и является востребованным в рамках современных ИАОС [20].

Использование системного подхода к объединению всех этих концепций в рамках одного инструмента (подсистемы принятия решений) позволили выйти на обобщённую последовательность обобщения данных и выработки решений (1).

$$M_k : D \rightarrow \{D_{ij}\} \rightarrow Map\{D_{ij}\} \rightarrow F \rightarrow r \quad (1)$$

где r – решение (выбранная альтернатива из множества решений R_k), а F – процедуры принятия решений. Эта модель предполагает наличие частных механизмов.

Механизмы, реализованные в ИАОС AESU

Частные механизмы, которые обеспечивают функциональность ИАОС делятся на штатные процедуры (выборки, статистические обобщения, процедуры расчёта оценок отдельных показателей) и специфические. Первые используются на всех этапах обобщения данных, согласно настройкам модели принятия решений M . Они не опираются на методы искусственного интеллекта и подключаются не из базы знаний, а из репозитория алгоритмов обучающей системы.

Специфические механизмы ориентированы на то, чтобы планировщик мог проверять различные гипотезы, опираясь на многообразие методов искусственного интеллекта. Кратко опишем основные из них.

Метод проверки гипотез на основе продукционной модели представления знаний Э. Поста. Он реализован на базе конструктора FLM_Builder [21] и позволяет формировать внешние фрагменты базы знаний в формате flm (рис. 1, справа). Они размещаются в репозитории баз знаний и ассоциируются с конкретными событиями образовательной среды через модель M . Машина вывода (решатель) для просчёта flm-файлов реализована на языке Python, ядро которого интегрировано в серверную часть ИАОС AESU. Таким образом, в обучающей систе-

ме встроен механизм проверки гипотез с помощью *продукционных экспертных систем*, формализующих граф вывода знаний.




Рис. 1. Окно конструктора экспертных систем FLM_Builder: формирование графа решений (справа) и характеристических функций терм-множеств (слева)

Самостоятельным механизмом, интегрированным с flm-моделями, является *метод нечёткой логики Л. Заде* [22]. Он может быть подключён на любом этапе работы модели *M* и реализует функции фазификации и дефазификации. Настройка термов и терм-множеств обеспечивается в том же конструкторе FLM_Builder, а запуск просчёта с учётом выбора предпочтительного алгоритма разрешения конфликтов реализованы через соответствующий API (рис. 1, слева).

Ещё одним механизмом проверки гипотез является использование *критерия Шортлиффа и Бьюкенена* [23]. Она предполагает, что каждая сложная по своей сути реакция/событие в ИАОС может быть учтено при анализе с разных сторон: одни гипотезы в процессе появления очередного события, могут повышать свой уровень достоверности, а другие – понижать. Для этого на событие, подвергающееся анализу, формируется множество гипотез и для каждой из них эксперт выставляет свои оценки, которые в дальнейшем позволяют оценить то, насколько эти гипотезы подтвердились на множестве событий. В дальнейшем результаты проверки используются как при формировании векторов входов в flm-файлы, так и для осуществления картирования. В первую очередь данный

механизм применяется при формировании компетентностного профиля учащихся [24].

Переходя от концепции к механизмам когнитивной компьютерной графики следует остановиться на механизмах картирования. Собственно, механизм картирования в ИАОС AESU представлен двумя видами карт: первые ориентированы на свёртку и концентрацию данных относительно структуры дидактического материала, а вторые – свёртку и концентрацию относительно активности учащегося (функциональный аспект). Оба они опираются на подготовленную в $Map\{D^{ij}\}$ структуру данных (параметрическую карту), но обрабатывают и анализируют её по-разному (в зависимости от специфики решаемой задачи).




Рис. 2. Примеры ККДЗ (слева) и антропоморфного образа в нотации UGVA (справа)

Структурное картирование реализовано в виде *когнитивных карт диагностики знаний* (ККДЗ) [25] и используется при анализе учебной ситуации с позиции обучающей системы (рефлексия). Она представляет из себя граф вида модели «маленького мира» [26], который соединяет в себе все семиотические элементы учебной ситуации из D^{ij} , используя в качестве подложки структуру дидакти-

ческого материала. На карту дополнительно вводится цветовая маркировка и возможность отображения данных из связанных структурных элементов учебного плана (сводная карта) [27]. Например, если в качестве масштаба взята учебная дисциплина, то её структура для учащегося на определённый момент обучения будет выглядеть так, как показано на рис. 2 (слева).

Функциональные карты реализованы в виде метода *унифицированного графического воплощения активности* (UGVA) [28]. Они базируются на пикт графике из Data Mining, где метод лиц Чернова [29] был развит до антропоморфного образа (работы В.А. Филимонова [30]), а затем адаптирован к отображению активных объектов [31]. За основу представления данных в этом методе взяты части условной человеческой фигуры, которые по своим размерам и цвету ставятся в соответствие с отдельными показателями из параметрической арты. Такой образ ориентирован для рефлексии своих достижений со стороны учащегося и, как правило, формируется относительно текущей учебной ситуации по всем изучаемым на текущий момент времени дисциплинам учебного плана (пример приведен на рис. рис. 2, справа).

Комбинация вывода значений r с опорой на карты двух типов, с учётом различных точек зрения и аспектов (системный подход), получило название *сквозного подхода* к анализу учебной ситуации [32]. Он реализует гибкую настройку связки аналитических функций и flm-файлов F с содержимым карт *Map*. В рамках единого механизма M этого удалось добиться за счёт использования метода модульной концентрации данных Г.А. Смирнова, адаптированного для принятия решений в ИАОС.

Завершая описание подходов и механизмов, на которых организована ИАОС AESU, следует сказать несколько слов о нейронных сетях. Их применение в качестве ведущего механизма для данной системы не применяется: это в первую очередь связано с тем, что обучающая система должна не только принимать решения, но и объяснять их в диалоге с учащимся. Концепция ХАИ [33] в этой области приложения не показывает высоких результатов. Но мы всё же экспериментируем с возможностью использования свёрточных нейронных сетей

для анализа содержимого карт (имитация визуальной интерпретации – поиск шаблонов, выделения закономерностей и аномалий).

Заключение

Системный подход к процессу обеспечения принятия объяснимых решений в ИАОС AESU позволил не только задействовать потенциал лежащих в её основе концепций и механизмов, но и за счёт их сочетания получить эмерджентный эффект в идее формирования нового подхода к организации работы обучающей системы. Если пользоваться классификацией уровней функциональных возможностей интеллектуальных систем В.К. Финна, то реализуемый в ИАОС AESU подход относится к 3-му уровню и даже обладает элементами 4-го [14]. А это значит, что исследования в этой области продолжаются, в обучающая система AESU будет развивать свои функциональные возможности.

Механизмы и подходы, описанные выше, предполагают не только комплексный подход к организации электронного обучения на базе интеллектуальных автоматизированных обучающих систем, но и с специфическую архитектуру построения такой системы. Очевидно, что раскрытие архитектурных решений нуждается в отдельной публикации и, к сожалению, выходит за рамки этой конкретной статьи.

Список литературы

1. Giannakos M. et al. The promise and challenges of generative AI in education // Behaviour & Information Technology. 2024. С. 1–27. DOI: 10.1080/0144929X.2024.2394886
2. Денисов М.Е., Сычёв О.А., Терехов Г.В. Онлайн-тренажер "Как это работает: Алгоритмы" // Информационные технологии. 2023, 29(5). С. 267–276. DOI: 10.17587/it.29.267-276
3. Карпенко А. П., Добряков А. А. Модельное обеспечение автоматизированных обучающих систем. Обзор // Машиностроение и компьютерные технологии. 2011. №. 7. С. 1-63.

4. Углев В.А. Автоматизированные обучающие системы нового поколения: основные черты и принципы организации // Перспективные методы и средства интеллектуальных систем: Материалы всероссийского научно-практического семинара и школы молодых ученых. Новосибирск: Изд-во НГТУ, 2015. С. 37–40.
5. Углев В.А. Представление учебной ситуации в интеллектуальных автоматизированных обучающих системах с позиций прикладной семиотики // Робототехника и искусственный интеллект: Материалы XIV Всероссийской научно-технической конференции с международным участием. - Красноярск: ЛИТЕРА-принт, 2022. - С. 76-83.
6. Рыбина Г.В. Интеллектуальные обучающие системы на основе интегрированных экспертных систем: учеб. пособие. – М.: Директ-Медиа, 2023. – 132 с.
7. Troussas, C., Krouska, A., Sgouropoulou, C.: Enhancing human-computer interaction in digital repositories through a mcda-based recommender system. *Advances in Human-Computer Interaction* 2021(1), 7213246. <https://doi.org/10.1155/2021/7213246>
8. Анохин П.К. Узловые вопросы теории функциональных систем – М.: Наука, 1980. – 200 с.
9. Анохин П.К. Проблема принятия решений в психологии и физиологии // Проблемы принятия решений: сборник статей. М.: Наука, 1974. С. 7-15.
10. Углев В.А. Модель учебной ситуации для интеллектуального планировщика обучающей системы // XXIII национальная конференция по искусственному интеллекту с международным участием (КИИ-2025). – СПб.: 2025. (в печати).
11. Осипов Г.С. От ситуационного управления к прикладной семиотике // Новости искусственного интеллекта. – 2002. – № 6. – С. 3-7.
12. Поспелов Д.А., Осипов Г.С. Прикладная семиотика // Новости искусственного интеллекта. 1999. №1. С. 9–35.
13. Углев В.А. Представление учебной ситуации как знака и подходы к её визуализации с помощью когнитивной графики // Поспеловские чтения: искусственный интеллект - проблемы и перспективы: Материалы Всероссийской конференции. - М.: Изд-во ФИЦ ИУ РАН, 2002. - 81-89.
14. Финн В.К. Искусственный интеллект: Методология. Применения. Филосо-

- фия. – М.: ЛЕНАНД, 2023. – 468 с.
15. Лефевр В.А. Лекции по теории рефлексивных игр. М.: Когито-Центр, 2009. – 218 с.
 16. Углев В.А. Базовая модель процессов рефлексии в интеллектуальных автоматизированных обучающих системах // Математические структуры и моделирование. №1. 2018. С. 111–121.
 17. Зенкин А. А. Когнитивная компьютерная графика. М.: Наука, 1991. – 192 с.
 18. Поспелов Д. А. Десять "горячих точек" в исследованиях по искусственному интеллекту // Искусственный интеллект и принятие решений. 2019. №. 4. С. 3–9.
 19. Han J., Kamber M. (2006). Data mining: concepts and techniques, 2nd. University of Illinois at Urbana Champaign: Morgan Kaufmann. 2006. – 560 p.
 20. Ilves K., Leinonen J., Hellas A. Supporting self-regulated learning with visualizations in online learning environments // Proceedings of the 49th ACM Technical Symposium on Computer Science Education, 2018, pp. 257–262. DOI: 10.1145/3159450.3159509
 21. Болсуновский Н.А., Пронин А.Д., Углев В.А. Конструктор продукционных экспертных систем с элементами нечёткой логики FLM_Builder и интеграция его моделей в пользовательские проекты// Нейроинформатика, ее приложения и анализ данных: XXX Всероссийский семинар. – Красноярск: ИВМ СО РАН, 2022.– С. 24-33.
 22. Zadeh L.A., Aliev R.A. Fuzzy logic theory and applications: part I and part II. World Scientific Publishing, New Jersey, USA. 2018.
 23. Джексон П. Введение в экспертные системы. М.: Вильямс, 2001. – 624 с.
 24. Uglev V., Shangina E. Assessment and visualization of course-level and curriculum-level competency profiles // Computational Science and Its Applications – IC-CSA 2023 Workshops. LNCS, vol. 14104. Springer, Cham. pp. 478–493. DOI: 10.1007/978-3-031-37105-9_32
 25. Uglev V.A. Cognitive Maps of Knowledge Diagnosis (CMKD): the essence of the method, classification, characteristics and synthesis principles // Novel & Intelligent Digital Systems: Proceedings of the 4th International Conference (NiDS 2024). NiDS 2024. Lecture Notes in Networks and Systems, vol 1170. Springer, Cham.

2023. pp. 594–605. https://doi.org/10.1007/978-3-031-73344-4_51
26. Milgram S. et al. The small world problem // *Psychology today*. 1967. Т. 2. №. 1. pp. 60–67.
27. Углев В.А., Смирнов Г.А. Отображение динамики учебного процесса с помощью когнитивной карты диагностики знаний // *Нейроинформатика, ее приложения и анализ данных: XXXII Всероссийский семинар*. – Красноярск: ИВМ СО РАН, 2024.– С. 101-106.
28. Углев В.А. Поддержка процесса принятия решений с использованием нотации унифицированного графического воплощения активности (UGVA) // *Вестник МГТУ им. Н.Э. Баумана. Сер. Приборостроение*. - 2023. - №3(144) - С. 125-140. <https://doi.org/10.18698/0236-3933-2023-3-125-140>
29. Chernoff H. The use of faces to represent points in k-dimensional space graphically. *Journal of the American Statistical Association*, vol. 68. 1973. pp. 361-368.
30. Филимонов В.А. Способ когнитивной визуализации многопараметрических компонентов системы // *Робототехника и искусственный интеллект: Материалы XIII Всероссийской конференции с международным участием*. – Красноярск: Литера-принт, 2021. – 136-140. https://aesu.ru/local/conference/_docs/2021/RAI-21_print.pdf
31. Uglev V., Meshkov S., Kuznetsov M. Methodology of Complex Visual Representation of Human Activity Using Cognitive Visualization // *Journal of Integrated Design and Process Science*, 2024. vol. 27(3-4). pp. 184-199. <https://doi.org/10.1177/10920617241289768>
32. Uglev V., Gavrilova T. Cross-Cutting Visual Support of Decision Making for Forming Personalized Learning Space // *Novel & Intelligent Digital Systems: Proceedings of the 2nd International Conference (NiDS 2022)*. NiDS 2022. Lecture Notes in Networks and Systems, vol 556. Springer, Cham. 2022. pp. 3-13. https://doi.org/10.1007/978-3-031-17601-2_1
33. Arrieta A.B., D'íaz-Rodríguez N., Del Ser J. et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information fusion*, 2020, pp. 82–115.

АРХИТЕКТУРА ФИЗИЧЕСКИ-ИНФОРМИРОВАННЫХ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ЭНЕРГЕТИЧЕСКИХ ПРОЦЕССОВ

И.Е. Старостин

Московский государственный технический университет гражданской авиации
(МГТУ ГА), *starostinigo@yandex.ru*

Математическое моделирование процессов различной физической и химической природы – важнейший этап решения задач проектирования и эксплуатации различных систем [1 – 3]. Для построения математических моделей упомянутых систем был разработан в рамках механики, электродинамики и современной неравновесной термодинамики метод математического прототипирования энергетических процессов (ММПЭП) – единый подход моделирования процессов различной физической и химической природы [4 – 9]. Соответственно получаемые ММПЭП модели различных систем получают корректными, т.е. не противоречащими общезначимым законам (законам сохранения, началам термодинамики, и т.д.), а также благодаря заданию функций состояния (например, в виде функциональных разложений) свойств веществ и процессов – физике конкретной системы [4, 5, 7 – 9].

В рамках ММПЭП определяются термодинамические силы, движущие процессы в системе в рамках законов сохранения (Рис. 1) [4, 5]. Однако термодинамические силы однозначно не определяют динамики системы [4, 5]; независимо от последних динамику системы определяют еще и кинетические свойства системы, «шкалой» которых является диссипативная матрица (Рис. 1), произведение которой на вектор термодинамических сил дает вектор скоростей протекания процессов [4, 5]. Динамика физических и химических процессов определяет динамику измеряемых параметров (ИП) и контролируемых параметров рассматриваемой системы (Рис. 1) [4, 5].



Рис.1. Факторы, определяющие протекание процессов различной физической и химической природы

Для получения в численном виде системы уравнений ММПЭП необходимо аналитически задать с точностью до экспериментально исследуемых коэффициентов (аппроксимационная теорема Вейрштрасса [10]) функции состояния для [4, 5, 7 – 9]:

- обратимые и приведенные необратимые составляющие диссипативной матрицы, через которые определяется диссипативная матрица [7];
- приведенной энтропии и приведенных внутренних энергий (или приведенной свободной энергии), через производные которой определяются потенциалы взаимодействия, приведенные теплоемкости и приведенные тепловые эффекты [8, 9];
- приведенных долей распределения некомпенсированных теплот, через которые определяются доли распределения некомпенсированных теплот [9];
- коэффициентов матрицы баланса [4, 5].

На упомянутые выше функции состояния ограничений не накладывается [7 – 9], поэтому эти функции состояния для свойств веществ и процессов (СВП) могут быть заданы в виде [9 – 12]:

- функциональных разложений [10];

- нейронных сетей, как универсального аппроксиматора [11];
- прочих моделей машинного обучения [12];
- через символьную регрессию [13, 14];
- аппроксимационных выражений [15].

Модели ММПЭП с заданными вышеописанными способами функций состояния для СВП представляют собой класс моделей, в котором методами теории идентификации из экспериментальных данных строится модель [16]. Упомянутые аналитические функции для СВП задаются как зависимости координат состояния (величин, однозначно характеризующих состояние системы независимо от ее предыстории [4, 5]), индивидуальных параметров экземпляра системы (параметров, меняющихся от экземпляра к экземпляру системы конкретного класса) и параметров, одинаковых для всех экземпляров систем конкретного класса [4 – 6]. Индивидуальные параметры выражаются через репрезентативные участки динамики ИП (РУДИП) [6, 16], поэтому целесообразно упомянутые аналитические функции для СВП строить как зависимости координат состояния и выбранных исследователем характеристик РУДИП, задаваемые с точностью до экспериментально исследуемых коэффициентов, одинаковых для систем рассматриваемого класса [6].

Дифференциальные уравнения ММПЭП могут быть решены как шаговыми, так и специальными методами решения, подразумевающими задание аналитических выражений решений [15]. Задание аналитических выражений общего решения системы дифференциальных уравнений ММПЭП существенно упрощает идентификацию модели из экспериментальных данных [15, 16], а значит ММПЭП целесообразно положить в основу физически информированных моделей машинного обучения [17 – 20]. При этом аналитическое выражение общего решения системы дифференциальных уравнений ММПЭП задается как зависимость от времени и от упомянутых характеристик РУДИП с точностью до экспериментально исследуемых коэффициентов, одинаковых для экземпляров систем рассматриваемого класса [6]. Система дифференциальных уравнений ММПЭП входит при этом в функцию потерь обучающихся моделей динамики системы и

модели для упомянутых аналитических функций состояния системы [17 – 20] (Рис. 2).

Следует также отметить, что на вход аналитических выражений для СВП целесообразно подавать некоторые признаки, представляющие аналитические зависимости от координат состояния и характеристик РУДИП (Рис. 2) [12, 21], представляющие собой составляющие зависимостей соответствующих СВП от упомянутых величин [12, 21, 22], что существенно упрощает аналитические выражения для СВП, а также делает упомянутые выражения более точными и адекватными [12, 22].




Рис. 2. Общая структура физически информированной модели машинного обучения на основе метода математического прототипирования энергетических процессов и ее обучение

Обучение показанных на Рис. 2 физически информированных моделей машинного обучения осуществляется путем расчета функции потерь (на Рис. 2 направление расчета показано тонкими черными стрелками), характеризующих величину невязки и отклонения расчетных значений ИП от соответствующих

экспериментальных данных ИП (Рис. 2), с последующей корректировкой функций состояния для СВП и аналитических выражений динамики состояния системы (на Рис. 2 показано толстыми белыми стрелками) [6, 17 – 20]. В результате чего получается обученная модель, применимая для решения практических задач [1 – 3], структура которой показана на Рис. 3 [6].



Рис. 3. Преобразованная аналитическая модель системы, применимая для решения практических задач

Аналитическое выражение динамики состояния системы может также принимать на вход признаки, являющиеся функцией времени и характеристик РУДИП (Рис. 4), аналогично представляющие собой составляющие зависимости соответствующих аналитических выражений динамики от упомянутых величин [12, 21, 22], что также существенно упрощает упомянутые аналитические выражения динамики системы и делает их более точными и адекватными [12, 22]. При этом сама динамика состояния системы непосредственно может быть задана методами [10 – 15] (Рис. 4А), либо путем задания с точностью до не связанных между собой дифференциальными уравнениями ММПЭП параметров аналитических выражений динамики состояния системы, вбирающих в себя все качественные особенности поведения системы, с последующим заданием методами [10 – 15] соответствующих выражений для параметров упомянутых аналитических выражений (Рис. 4Б) [6].

В аналитическое выражение динамики состояния системы, показанной на Рис. 4Б, вкладывается физика рассматриваемой системы [6]. Отсюда структура аналитического выражения, показанная на Рис. 4Б будет корректной [6], а значит, преобразованная математическая модель системы, показанная на Рис. 3, может быть обучена в соответствие со схемой, показанной на Рис. 5.




Рис. 4. Структура аналитического выражения динамики состояния системы

В схеме, показанной на Рис. 5, обучение ведется (показанные на Рис. 5 толстые белые стрелки) только на основе погрешностей, рассчитанных ИП по сравнению с соответствующими экспериментальными значениями (показанные на Рис. 5 черные тонкие стрелки). Отсюда, приведенная на Рис. 5 схема обучения аналитической физически информированной модели машинного обучения характеризуется простотой обучения по сравнению со схемой, показанной на Рис. 2.




Рис. 5. Обучение аналитических физически информированных моделей

Таким образом, построение рассмотренных в настоящей работе физически информированных моделей машинного обучения на базе ММПЭП сводится к построению признаков, показанных на Рис. 2, 4, методами [21] с использованием вычислительного эксперимента [21, 23] и методов символьной регрессии [13, 14], к построению аналитического выражения динамики, вбирающего в себя качественные особенности поведения системы и связей между параметрами упомянутых аналитических выражений динамик [6] также с использованием вычислительного эксперимента [6, 23] с дальнейшим построением моделей машинного обучения [10 – 14] или аппроксимационных моделей [15] для соответствующих характеристик (см. Рис. 2, 4). Для построения упомянутых моделей, а также для вышеупомянутого построения признаков, аналитических выражений динамики состояния системы могут использоваться методы AutoML [24]. Отсюда в силу единства ММПЭП для моделирования процессов различной физической и химической природы предложенный подход может быть положен в основу методов AutoML для построения моделей систем различной физической и химической природы. Список литературы

1. Норенков И.П. Основы автоматизированного проектирования / И.П. Норенков. — М.: Издательство МГТУ им. Баумана. — 2002. — 333 с.
2. Колодежный Л.П. Надежность и техническая диагностика / Л.П. Колодежный, А.В. Чернодаров. — М.: ВУНЦ ВВС ВВА им. Н.Е. Жуковского и Ю.А. Гагарина. — 2010. — 452 с.
3. Барзилович Е.Ю. Модели технического обслуживания сложных систем / Е.Ю. Барзилович. — М.: Высшая Школа. — 1982. — 233 с.
4. Старостин И.Е. Виды и формы представления основных уравнений метода математического прототипирования энергетических процессов / И.Е. Старостин, С.П. Халютин, В.В. Париевский // Электропитание. — 2022. — № 4. С. 4 - 14.
5. Старостин И.Е. Программная реализация методов современной неравновесной термодинамики. И система симуляции физико-химических процессов SimulationNonEqProcSS v.0.1.0 / И.Е. Старостин, А.Г. Степанкин. — Бо Бассен, Маврикий: Lambert academic publishing. — 2019. — 127 с.
6. Старостин И.Е. Архитектура математического ядра цифровых двойников различных физико-химических систем на базе метода математического прототи-

- пирования энергетических процессов / И.Е. Старостин, С.И. Гавриленков // Надежность и качество сложных систем. — 2024. — № 4. С. 160 – 168. DOI: 10.21685/2307-4205-2024-4-17.
7. Старостин И.Е. Корректное задание функций состояния для диссипативной матрицы, входящей в уравнения метода математического прототипирования энергетических процессов / И.Е. Старостин // Надежность и качество сложных систем. — 2025. — № 1. С. 28–35. DOI: 10.21685/2307-4205-2025-1-4.
 8. Старостин И.Е. Задание функций состояния для потенциалов взаимодействия, приведенных теплоемкостей и приведенных тепловых эффектов, входящих в уравнения метода математического прототипирования энергетических процессов / И.Е. Старостин, С.И. Гавриленков // Надежность и качество сложных систем. — 2025. — № 1. С. 36–43. DOI: 10.21685/2307-4205-2025-1-5.
 9. Старостин И.Е. К вопросу применения методов символьной регрессии для построения цифрового двойника систем различных физико-химических систем на базе метода математического прототипирования энергетических процессов / И.Е. Старостин // Труды Международного симпозиума «Надежность и качество». Т. 1. Пенза, 26 мая – 1 июня 2025 г. — 2025. С. 68 - 74.
 10. Дзядык В.К. Введение в теорию равномерного приближения функции полиномами / В.К. Дзядык. — М.: Наука. — 1977. — 512 с.
 11. Haykin S. Neural Networks. A Comprehensive Foundation / S. Haykin. — Upper Saddle River, USA: Prentice hall. — 2006. — 1105 p.
 12. Flach P. Machine Learning. The Art and Science of Algorithms that Make Sense of Data / P. Flach. — Cambridge: Cambridge University Press. — 2015. — 400 p.
 13. Стрижов В.В. Методы индуктивного порождения регрессионных моделей / В.В. Стрижов. — М.: Вычислительный центр им. А. А. Дородницына Российской акад. наук. — 2008. — 56 с.
 14. Данг Тхи Фук, Дивеев А.И., Софронова Е.А. Решение задач идентификации математических моделей объектов и процессов методом символьной регрессии / Тхи Фук Данг, А.И. Дивеев, Е.А. Софронова // Cloud of Science. — 2018. — Т. 5, № 1. С. 147 — 162.
 15. Калиткин Н.Н. Численные методы / Н.Н. Калиткин. — СПб: БХВ-Петербург. — 2011. — 592 с.

16. Eykhoff P. Systems identification: parametrs and state estimation / P. Eykhoff. — Eindhoven, Netherlands: University of technology. — 1975. — 680 p.
17. Зрелова Д.П. Модели физически информированных / осведомленных классических Лагранжевых / Гамильтоновых нейронных сетей в глубоком обучении / Д.П. Зрелова, С.В. Ульянов // Современные информационные технологии и ИТ-образование. — 2022. — Т. 18, № 2. С. 310 — 325.
18. Garleo G. Machine learning and the physical sciences / G. Garleo, et. al. // Reviews of Modern Physics. — 2019. — No. 91(4). 045002. DOI: <https://doi.org/10.1103/RevModPhys.91.045002>
19. Кошелев К.Б. Применение физически информированной нейронной сети для модельных задач гидрологии / К.Б. Кошелев, С.В. Стрижак // Международная конференция «Марчуковские научные чтения 2024» (МНЧ-2024), 7 – 11 октября 2024 г. — 2024. С. 104 – 104.
20. Бузаев Ф.А. Решение уравнения переноса одномерного излучения с помощью физически информированных нейронных сетей: анализ производительности / Ф.А. Бузаев, Д.А. Деркач, Д.С. Ефременко // Светотехника. — 2025. — № 2. С. 70 — 76.
21. Старостин И.Е. Программная реализация на базе СКМ Scilab методологии построения математической модели системы из уравнений физико-химических процессов в ней / И.Е. Старостин // Труды Международного симпозиума «Надежность и качество». — 2020. — Т. 1. С. 41 — 44.
22. Старостин И.Е. Задание функций состояния для величин, входящих в формализм потенциально-потокowego метода описания динамики физико-химических процессов / И.Е. Старостин // Материалы XVI международной научно-практической конференции «Инновационные информационные и коммуникационные технологии». — 2019. С. 317 — 322.
23. Малинецкий Г.Г. Математические основы синергетики: Хаос, структуры, вычислительный эксперимент / Г.Г. Малинецкий. — М.: Ленанд. — 2017. — 312 с.
24. Hutter F. Automated Mashine Learning / F. Hutter, L. Kotthoff, J. Vanshoren. — New York, USA: Springer. — 2019. — 258 с.

КРОСС-ДОМЕННОЕ ОБУЧЕНИЕ НА МАЛЫХ ВЫБОРКАХ ДЛЯ ЗАДАЧИ СЕГМЕНТАЦИИ МЕДИЦИНСКИХ СНИМКОВ

М.Н. Фаворская

¹ Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева, Институт информатики и телекоммуникаций, кафедра информатики и вычислительной техники, *favorskaya@sibsau.ru*

В настоящее время обучение глубоких нейросетевых моделей, как правило, выполняется на нескольких наборах данных с целью повышения обобщаемости моделей. Однако наборы данных могут быть не согласованы, иметь разные распределения экземпляров, что приводит к ошибкам обучения или фактически к созданию разных моделей, обученных на конкретных наборах данных. Одним из способов решения данной проблемы является адаптация наборов данных к глубокой нейросетевой модели в условиях малого количества обучающих экземпляров. Проблема обучения с малым количеством экземпляров можно сформулировать как обучение «по экземпляру на набор данных», а не по «экземпляру на класс», что позволяет проводить кросс-доменное обобщение в условиях ограниченных наблюдений и смещенных распределений. Такая постановка задачи особенно актуальна для сегментации медицинских снимков, количество которых, как правило, ограничено.

Традиционное понимание обучения глубокой нейросетевой модели основано на итеративном процессе ручного выбора гиперпараметров и конфигураций архитектуры, обучении модели и мониторинге ее производительности на проверочном (валидационном) наборе данных. Адаптивная парадигма обучения формулируется как «не новая модель» (no new model, nn model). Одной из первых публикаций по данному вопросу была работа [1], в которой формулировались основные принципы само-конфигурируемых моделей на примере известной архитектуры U-Net для сегментации медицинских снимков. Свойства набора данных суммируются в «отпечатке набора данных» (dataset fingerprint), на основе которого формируется набор эвристических правил. Эвристические правила выводят зависящие от набора данных гиперпараметры обработки. Они дополняют-

ся параметрами плана (blueprint). Далее выбирается независимая от данных архитектура, которая создает «отпечаток обработки» (pipeline fingerprint). Несколько созданных таким образом архитектур обучаются с помощью «отпечатков обработки» путем 5-кратной перекрестной проверки. На завершающем этапе модель nnU-Net автоматически подбирала оптимальный ансамбль таких архитектур. При необходимости выполнялась постобработка медицинских снимков.




Рис.1. Нейросетевые архитектуры, сгенерированные моделью nnU-Net для набора данных ACDC [1].

Если алгоритмический подход к настройке методов формулируется как задача оптимизации в конкретной области, то модель nnU-Net автоматически генерирует методы обучения с использованием эвристических правил для ранее неизвестных наборов данных без необходимости дальнейшей оптимизации. На рис. 1 приведены примеры архитектур, сгенерированных моделью nnU-Net для набо-

ра данных ACDC (The Automated Cardiac Diagnosis Challenge), для сегментации 2D и 3D изображений.

Следует отметить, что модель nnU-Net, основанная на предварительной обработке, правильном выборе гиперпараметров и реализации процедуры обучения, имеет определенную область применения, например, при требовании обобщения модели на наборах данных с относительно небольшим количеством экземпляров. Однако иногда утверждение о том, что выбор таких конфигураций часто важнее фактической архитектуры сети, подвергается сомнению. Так, модели с модифицированной архитектурой UNet++ [2] и UNet3+ [3] показали лучшие результаты сегментации за счет лучшей производительности, но ценой увеличения структурной и вычислительной сложности.

Тем не менее, модель nnU-Net продолжает использоваться и сравниваться с другими аналогичными моделями сегментации на различных наборах медицинских данных особенно для 3D сегментации. В работе [4] были проведены исследования изображений пищевода со злокачественными опухолями с использованием моделей nnU-Net и U-Mamba [5]. Для экспериментов были выбраны две модели nnU-Net (2D U-Net и 3D full resolution (FullRes) U-Net) и четыре модели U-Mamba (2D U-Mamba_Bot, 3D U-Mamba_Bot, 2D U-Mamba_Enc и 3D U-Mamba_Enc). Двумерная модель U-Net использует традиционную структуру кодера-декодера с пропущенными связями, которые объединяют характеристики высокого и низкого разрешения и тем самым повышают точность сегментации. Трёхмерная сеть U-Net FullRes расширяет эту архитектуру до трёхмерной области, делая ее особенно эффективной для анализа 3D данных благодаря сбору пространственной информации по нескольким срезам. Блок U-Mamba является относительно новым механизмом для одновременного сбора краткосрочных и долгосрочных зависимостей в данных. Благодаря интеграции сверточных нейронных сетей (СНС) и моделей пространства состояний, этот блок сочетает в себе преимущества извлечения локальных признаков и моделирования динамических систем. СНС, изначально разработанные для последовательного анализа данных, в данном случае используются для эффективного кодирования долго-

срочных пространственных зависимостей, что позволяет моделировать сложные пространственные отношения, не требуя ресурсоемких операций механизмов внимания. При этом СНС извлекают локальные признаки высокого разрешения, дополняя возможности моделей пространства состояний по глобальному пространственному моделированию. Такая конструкция позволяет блоку U-Mamba поддерживать вычислительную эффективность при сборе детального пространственного контекста. Архитектуры сетей nnU-Net, U-Mamba-Enc и U-Mamba-Bot представлены на рис. 2.




Рис.2. Архитектуры сетей: А nnU-Net, Б U-Mamba-Enc, В U-Mamba-Bot [5].

Как видно из рис. 2Б и 2В модели U-Mamba построены с использованием специальных U-Mamba блоков. Результаты обнаружения злокачественных опухолей и их сегментации на проверочном и тестовом наборах данных моделей обоих семейств показали близкие результаты по метрикам DSC (Dice Similarity Coefficient) и 95% Hausdorff distance при толщине срезов 5 мм и 1 мм.

Эффективный метод кросс-модальной неконтролируемой адаптации доменов при использовании аннотированных КТ-снимков для улучшения сегмента-

ции МРТ-снимков предложен в работе [6]. Он включает три последовательных этапа:

1. Перенос знаний от КТ-снимков в МРТ-снимки на основе модели nnU-Net и условного генератора CGAN с применением техники неконтролируемой адаптации доменов. Особое внимание уделено согласованности на уровне входных данных, признаков и выходных данных, а также стиля и контента изображений. В результате формируется универсальная модель сегментации Uni-Net.

2. Предварительно обученная модель Uni-Net дообучается на маркированных КТ-снимках и на МРТ-снимках с псевдометками. Кроме того, новая модель nnU-Net обучается с нуля, названная MR-Net, с использованием только МРТ-снимков с псевдометками.

3. Далее настроенные модели Uni-Net и MR-Net применяются для генерации и выбора надежных псевдометок на основе согласованности.

В условиях ограниченных вычислительных ресурсов авторами разработана облегченная модель nnU-Net, названная LW-Net для решения поставленной задачи. Проведенные эксперименты с наборами данных в рамках соревнования FLARE2024, задача 3 показали, что разработанная модель LW-Net демонстрирует хорошие показатели по метрикам DSC и NSD (Normalized Surface Dice). Несмотря на сложный алгоритм обучения, авторы работы [6] показали, что модель nnU-Net может быть успешно применена и при кросс-модальном неконтролируемом обучении.

В работе [7] представлено несколько иное применение модели nnU-Net, а именно использование для кросс-модального синтеза и закрашивания медицинских изображений. Гипотеза была проверена на наборах данных BraTs 2023 и Synthrad2023 соответственно. Объективные эталонные метрики MAE, MSE, SSIM и PSNR показали, что такая адаптированная модель nnU-Net превосходит методы на основе генеративно-состязательных сетей.

Таким образом, модель nnU-Net показывает многообещающие результаты в областях, когда обучающих экземпляров недостаточно для применения стандартных методов обучения глубоких нейросетевых моделей при сегментации

изображений.

Список литературы

1. nnU-Net: A self-configuring method for deep learning-based biomedical image segmentation / F. Isensee et al. // Nat Methods. — 2021. — Vol. 18. — pp. 203–211.
2. UNet++: Redesigning skip connections to exploit multiscale features in image segmentation / Z. Zhou et al. // IEEE Trans. Med. Imaging. — 2020. — Vol. 39. — pp. 1856–1867.
3. UNet 3+: A full-scale connected UNet for medical image segmentation / H. Huang et al. // The 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, Barcelona, Spain, 2020, pp. 1055–1059.
4. Comparative analysis of U-Mamba and no new U-Net for the detection and segmentation of esophageal cancer in contrast-enhanced computed tomography images / Y. Hu et al. // Quant Imaging Med Surg. — 2025. — Vol. 15. — no. 3. pp. 2119–2131.
5. Ma J, Li F, Wang B. U-Mamba: Enhancing long-range dependency for biomedical image segmentation. E-print: <https://arxiv.org/abs/2401.04722>
6. Rethinking nnU-Net for cross-modality unsupervised domain adaptation in abdominal organ segmentation / Z. Chen et al. // In: Fast, Low-Resource, Accurate Robust Organ and Pan-cancer Segmentation. (FLARE 2024). J. Ma, B. Wang (eds). — 2026. — LNCS. — Vol. 15717. — Springer, Cham. — pp. 153–163.
7. Adapted nnU-Net: A robust baseline for cross-modality synthesis and medical image inpainting / A. Longuefosse, et al. // In: Simulation and Synthesis in Medical Imaging (SASHIMI 2024). V. Fernandez, J.M. Wolterink, D. Wiesner, S. Remedios, L. Zuo, A. Casamitjana (eds) — 2025. — LNCS. — Vol. 15187. — Springer, Cham. — pp. 24–33.

ИССЛЕДОВАНИЕ КАЧЕСТВА И ПРОИЗВОДИТЕЛЬНОСТИ РАБОТЫ АЛГОРИТМОВ СЕМЕЙСТВА YOLO В ЗАДАЧЕ РАСПОЗНАВАНИЯ ОБЪЕКТОВ МАЛЫХ РАЗМЕРОВ²

И.С. Фомин¹, А.И. Андреев²

¹Центральный научно-исследовательский и опытно-конструкторский институт
робототехники и технической кибернетики (ЦНИИ РТК)

²Санкт-Петербургский Политехнический университет Петра Великого (СПбПУ),
i.fomin@rtc.ru

Аннотация

В работе представлены результаты исследования нейронных сетей для обнаружения объектов YOLO применительно к обнаружению объектов малого размера. Сеть обучалась обнаружению средних и больших объектов, потому размеры в единицы пикселей требуют усложнения подхода. Проведен обзор различных детекторов объектов. Наилучший баланс между качеством и производительностью показала модель YOLOv8s, достигшая высоких показателей метрик mAP50 (0,968), mAP50-90 (0,647), Precision (0,933), Recall (0,949) и F1-score (0,941) при средней скорости обработки кадров 42 FPS. Для повышения точности распознавания проведено дообучение модели до 200 эпох, а также интеграция трекера BoT-SORT, что позволило сократить количество ложных срабатываний на фоновые объекты и повысить метрики Precision, Recall и F1-score на 4, 3 и 3% соответственно. Тестирование на встраиваемых платформах NVIDIA Jetson подтвердило возможность работы YOLOv8s в реальном времени на Jetson Xavier (до 45 FPS в формате TensorRT 8), а для Jetson TX2 рекомендовано использование облегченной модели YOLOv8n при снижении разрешения входных данных.

Ключевые слова: обнаружение объектов, малый размер, нейронные сети, YOLO, встраиваемые вычислители

Введение

² Результаты получены в рамках выполнения государственного задания Минобрнауки России №075-00553-25-00 от 25.12.2024 «Исследование методов анализа слабоструктурированных данных, обработки знаний и создания когнитивных агентов на базе комбинированных глубоких нейронных сетей» (FNRG-2025-0008 1024050200009-5-1.2.1;2.2.2).

Современные нейронные сети демонстрируют высокое качество работы в различных областях. Они активно применяются в беспилотном транспорте, видеонаблюдении, промышленной автоматизации. Нейронные сети для обнаружения объектов достигли впечатляющих результатов на многих задачах. Однако, обнаружение объектов малого размера по сравнению с размером кадра, менее 0,5%, остается для них сложной задачей в силу особенностей архитектуры и обучающих наборов данных, предназначенных прежде всего для работы с большими объектами, занимающими 10 и более процентов кадра.

Вторая важная проблема, которая возникает при практическом использовании нейронных сетей – их адаптация для использования в конечном устройстве. В задачах робототехники всегда присутствуют ограничения по габаритам вычислителя и потребляемой им энергии, а значит, чтобы решать интеллектуальные задачи по обнаружению объектов на борту требуется упростить сеть и перенести ее на встраиваемый вычислитель.

В данной работе будут рассмотрен выбор архитектуры нейросетевого детектора, его обучение для обнаружения объектов малого размера и применение дополнительных методов для повышения качества обнаружения, а также адаптация обученных сетей для использования на встраиваемых вычислителях семейства Nvidia Jetson.

1.Существующие решения

Для решения задачи обнаружения объектов на изображениях достаточно давно используют нейросетевые детекторы. Эта задача начиналась с применения классификатора к предположениям о положениях объектов, затем предположения начали предсказывать с использованием отдельной нейронной сети и потом связали все в единую архитектуру. Так появилась группа двухэтапных нейросетевых детекторов, сейчас последние в серии работ Faster R-CNN [1] (только обнаружение) и Mask R-CNN [2] (обнаружение + сегментация). Другой подход – поиск объектов по сетке, адаптированный для использования в нейронной сети. Область изображения разделяется на ячейки, для каждой из которой предсказывается отклик на ограниченное количество возможных форм и размеров объек-

тов. Это так называемые одноэтапные (single-shot) детекторы. Первым таким подходом был Single Shot Detector (SSD) [3], вслед за ним YOLO [4]. Сейчас также есть и более современные решения, развивающие и двухшаговый и одношаговый подход, например, Sparse R-CNN [5] и CenterNet [6].

Среди сетей, однозначно хорошо себя показывающих для встраиваемых устройств можно отметить ветку развития однопроходных детекторов SqueezeDet [7] и алгоритмы, основанные на EfficientDet [8]. Особняком стоят сети семейства YOLO – они не только постоянно развиваются, новые версии выходят каждый год. На сегодняшний день существуют удобные средства для их обучения. Также они поддерживают широкие возможности по интеграции на различные встраиваемые устройства. Для для многих платформ YOLO предоставляют лучшее соотношение по качеству и быстродействию, именно поэтому они были выбраны для исследования в данной работе.

2. Выбранные для исследования модели

На сегодняшний день существует более 12 версий алгоритмов YOLO. Каждая версия включает несколько вариантов архитектур (nano (n), small (s), medium (m), large (l) и extra large (x)), различающихся числом параметров и глубиной, что позволяет адаптировать модель под конкретные ресурсы. Для комплексного сравнения поколений и масштабов архитектур в данной работе рассматриваются YOLOv5n, YOLOv8n, YOLOv8s, YOLOv8m, YOLOv11n, YOLOv11s и YOLOv11m как наиболее ключевые версии разных поколений. YOLOv5 использует архитектуру с блоками CSP и PANet, обеспечивая баланс между скоростью и точностью. YOLOv8 перешла к безякорному подходу (anchor-free), обновила архитектуру с использованием блоков C2f и улучшила систему потерь. YOLOv11 продолжает развитие, внедряя RepC3-блоки и улучшенные FPN-структуры для повышения точности и скорости.

3. Используемый набор данных

В качестве объектов изучения были выбраны объекты малого размера в воздушной среде (например, птицы, воздушные шары, дроны, пчелы и пр.) поскольку их детектирование представляет собой характерный пример задачи рас-

познавания малогабаритных объектов в компьютерном зрении. Такие объекты на большом отдалении могут занимать менее 1% площади кадра, и обладать крайне низкой пиксельной информативностью, что усложняет выделение значимых признаков на фоне шумов и текстурного разнообразия окружающей среды, а их высокая скорость перемещения приводит к межкадровой нестабильности и размытию, что требует от моделей не только чувствительности к мелкомасштабным деталям, но и устойчивости к динамическим искажениям.

Для обучения модели использовался комбинированный набор данных, сформированный на основе открытых источников. После фильтрации от поврежденных и повторяющихся файлов был сформирован датасет, состоящий из 14862 изображений для обучения и 4802 изображений для тестирования (76 % и 24 %), которые охватывают различные условия, такие как разные углы обзора, разное освещение (день, вечер, ночь), а также разные фоновые сцены (городские пейзажи, природные ландшафты и т.д.). Каждое изображение в наборе имеет разметку, соответствующую формату, используемому моделью YOLO.

4. Экспериментальное исследование

Для исследования качества работы алгоритма выполнялось обучение на сформированном наборе данных из открытых источников, а также тестирование на собственном закрытом наборе данных, содержащем тестовые данные из исходного набора и целевые объекты для обнаружения. Оценка качества выполнялась стандартными средствами, входящими в пакет Ultralytics [9], который использовался для обучения всех рассматриваемых архитектур. Все обнаружения оценивались начиная с порога уверенности в 0,25. Невысокий порог важен, т.к. слаботекстурированные малоразмерные объекты регулярно имеют низкую уверенность нейронной сети и при повышении порога радикально падает полнота обнаружения. Методы оценки включают в себя стандартные метрики качества обнаружения объектов mAP@50, mAP@50-90, точность (Precision), полноту (Recall), а также F1-меру. Кроме того, оценивалась частота обработки кадров при обнаружении (FPS). Результаты, полученные на бытовом вычислителе Nvidia RTX 3060Ti представлены в таблице.

Результаты обучения и тестирование сетей семейства YOLO

Модель	mAP50	mAP50-90	Precision	Recall	F1-score	FPS
YOLOv5n	0,9595	0,5979	0,9085	0,9150	0,9117	44
YOLOv8n	0,9615	0,6214	0,9177	0,9358	0,9267	45
YOLOv8s	0,9681	0,6468	0,9325	0,9492	0,9408	42
YOLOv8m	0,9700	0,6602	0,9348	0,9567	0,9456	27
YOLOv11n	0,9626	0,6286	0,9237	0,9411	0,9323	40
YOLOv11s	0,9679	0,6453	0,9306	0,9490	0,9397	37
YOLOv11m	0,9680	0,6400	0,9282	0,9419	0,9350	29

По всем метрикам, за исключением FPS, YOLOv8m демонстрирует наилучший результат: mAP50 (0,970), mAP50-90 (0,660), Precision (0,935), Recall (0,957) и F1-score (0,946). Это достигается за счет более глубокой архитектуры и увеличенного числа параметров, что позволяет ей лучше запоминать и обобщать данные. По скорости обработки кадров лидируют YOLOv8n (45 FPS) и YOLOv5n (44 FPS), благодаря компактности и низкой вычислительной нагрузке. Среди протестированных моделей YOLOv8s демонстрирует наилучший баланс между точностью и скоростью работы, именно она была выбрана для дальнейших исследований.

Практическое рассмотрение результатов работы сетей на собственном наборе данных, который включал в себя, в частности, видеозаписи целевых объектов показало, что нередко возникают ошибки обнаружения, связанные с паразитными объектами на короткое время появляющимися в кадре. Поэтому для практического использования был также интегрирован алгоритм сопровождения BoT-SORT [10], что позволило повысить все метрики качества на несколько процентов.

5. Перенос на встраиваемые вычислители

При интеграции модели в мобильные платформы алгоритм может быть запущен на различных встраиваемых вычислителях, а также переведен в оптимальный для работы на этом вычислителе формат с целью повышения произво-

длительности, уменьшения времени отклика и адаптации под особенности аппаратного обеспечения.

Тестирование алгоритма проводилось на встраиваемых вычислителях Nvidia Jetson Xavier и Jetson TX2 в формате PyTorch, TorchScript. Также были рассмотрены различные уровни квантизации весов для целочисленных расчетов, включая TensorRT 32, TensorRT16 и TensorRT 8 (для Jetson Xavier), как показано в таблице.

Быстродействие моделей на встраиваемых вычислителях

Формат	PyTorch	TorchScript	TensorRT 32	TensorRT 16	TensorRT 8
YOLO 8s 1280x1280					
Jetson Xavier	10	10	11	25	45
Jetson TX2	2	2	4	6	-
YOLO 8n 1280x1280					
Jetson Xavier	21	35	32	66	99
Jetson TX2	6	6	13	20	-
YOLO 8n 1280x1280					
Jetson TX2	3	3	8	12	-
YOLO 8n 640x640					
Jetson TX2	11	12	26	36	-

Производительность Jetson Xavier позволила запускать и использовать модель YOLO8s с разрешением 640x640 в форматах TorchScript, TensorRT 32, TensorRT 16 и TensorRT 8 при достаточной скорости обработки кадров (более 30 FPS). При использовании алгоритма с разрешением 1280x1280 модель потребовалось перевести в формат TensorRT 8. Производительности Jetson TX2 хватило только на запуск минимальной модели YOLO 8n. Перевод моделей в формат хранения данных, адаптированный для запуска на встраиваемых вычислителях не оказал существенного влияния на точность.

Заключение

В работе было проведено исследование нейронных сетей для обнаружения объектов семейства YOLO в задаче обнаружения объектов малого размера. В силу сравнительно небольшого набора данных в несколько тысяч примеров большая часть моделей показала качество работы, признанное успешным для решения поставленной задачи.

Тестирование на целевых видеозаписях позволило выявить проблемы обнаружения, не решившиеся посредством подбора параметров обучения, но подключение внешнего трекера позволило исключить паразитные обнаружения и повысить общее качество на несколько процентов.

Перенос моделей на встраиваемые вычислители для использования непосредственно на борту мобильного робота показал, что достаточной производительностью обладает только сеть YOLO8n. Она показала быстроедействие от приемлемого (21 FPS) до полностью подходящего (60+ FPS) на производительном Jetson Xavier. Также на существенно менее производительном Jetson TX2 возможно добиться приемлемого быстрогодействия от этой сети при снижении размера кадра и высокой квантизации.

В дальнейшем предполагается развить полученные результаты для переноса технологии обнаружения объектов на встраиваемые вычислители, в которых нет поддержки форматов PyTorch и TensorRT, включая OrangePi5 (Rockchip3588) и OrangePi APro, так как именно такие вычислители предлагают наилучшее соотношение между стоимостью, доступностью и производительностью. Кроме того, будет проведена доработка алгоритма сопровождения для работы полного предложенного алгоритма обнаружения подвижных малоразмерных объектов на встраиваемом вычислителе.

Список литературы

1. Ren S. Faster r-cnn: Towards real-time object detection with region proposal networks / S. Ren, K. He, R. Girshick, J. Sun // Advances in neural information processing systems. – 2015. – Т. 28.

2. He K. Mask r-cnn / K. He, G. Gkioxari, P. Dollár, R. Girshick // Proceedings of the IEEE international conference on computer vision. – 2017. – С. 2961-2969.
3. Liu W. Ssd: Single shot multibox detector / W. Liu, D. Anguelov, D. Erhan [и др] // European conference on computer vision. – Cham : Springer International Publishing, 2016. – С. 21-37.
4. Redmon J. You only look once: Unified, real-time object detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – С. 779-788.
5. Chen T. A simple framework for contrastive learning of visual representations / T. Chen, S. Kornblith, M. Norouzi, G. Hinton // International conference on machine learning. – PmLR, 2020. – С. 1597-1607.
6. Duan K. Centernet: Keypoint triplets for object detection / K. Duan, S. Bai, L. Xie [и др.] // Proceedings of the IEEE/CVF international conference on computer vision. – 2019. – С. 6569-6578.
7. Wu B. Squeezedet: Unified, small, low power fully convolutional neural networks for real-time object detection for autonomous driving / B. Wu, F. Iandola, P. H. Jin, K. Keutzer // Proceedings of the IEEE conference on computer vision and pattern recognition workshops. – 2017. – С. 129-137.
8. Tan M. Efficientnet: Rethinking model scaling for convolutional neural networks / M. Tan, Q. Le // International conference on machine learning. – PMLR, 2019. – С. 6105-6114.
9. Ultralytics. Ultralytics YOLO Docs. 2024. URL: <https://docs.ultralytics.com/ru/usage/cfg/> (дата обращения: 13.04.2025).
10. Aharon N. BoT-SORT: Robust associations multi-pedestrian tracking / N. Aharon, R. Orfaig, B. Z. Bobrovsky // arXiv preprint arXiv:2206.14651. – 2022. URL: <https://arxiv.org/pdf/2206.14651> (дата обращения: 12.05.2025).

БАЙЕСОВСКАЯ КАЛИБРОВКА ЦИФРОВОГО ДВОЙНИКА РЕАГИРОВАНИЯ ПОЖАРНО-СПАСАТЕЛЬНЫХ ПОДРАЗДЕЛЕНИЙ НА ОСНОВЕ РЕТРОСПЕКТИВНЫХ ДАННЫХ

Р.Ш. Хабибулин

Академия Государственной противопожарной службы МЧС России,

kh-r@yandex.ru

Пожары на объектах топливно-энергетического комплекса (далее – ТЭК) одни из наиболее опасных техногенных событий. Их динамика характеризуется быстрым развитием и высоким риском эскалации. Принятие управленческих решений при реагировании на такие пожары играет ключевую роль в предотвращении катастрофических последствий масштабных пожаров на объектах ТЭК.

Современные методы управления безопасностью всё чаще обращаются к технологиям интеллектуализации, включая концепции цифровых двойников [1-3]. Разрабатываемый статистический цифровой двойник (далее – ЦД) [4] представляет собой математико-вычислительную модель, воспроизводящую развитие фаз реагирования пожарно-спасательных подразделений (далее – ПСП).

Ключевой задачей повышения качества ЦД, а вместе с тем и повышения точности прогнозирования является согласование результатов вычислений в ЦД с реальными данными. Для решения этой задачи выполняется процедура калибровки параметров по ретроспективной базе пожаров, которая обеспечивает:

- достоверность предсказаний времени фаз реагирования ПСП;
- адекватность вероятностей переходов между фазами реагирования;
- выявление влияния условий (например, удалённость пожарно-спасательной части, вид огнетушащих веществ);
- расчёт управленческих риск-метрик.

Таким образом, калибровка ЦД – необходимое условие превращения его в инструмент сценарного анализа и элемент комплексной системы поддержки принятия решений (далее – СППР).

Цель исследования сформулирована следующим образом: обосновать применение байесовской калибровки параметров ЦД реагирования ПСП, пока-

зять её преимущества по сравнению с частотными и робастными методами на примере базы пожаров за период 2009–2021 гг. (объекты защиты – нефтебазы и нефтехранилища).

Процесс реагирования пожарно-спасательных подразделений можно представить как последовательность фаз, каждая из которых характеризуется определенной длительностью. На основе анализа 194 пожаров на нефтебазах и нефтехранилищах выделены шесть ключевых временных фаз (в минутах):

- τ_1 – время от обнаружения до сообщения о пожаре;
- τ_2 – время от сообщения до прибытия первого подразделения;
- τ_3 – время от прибытия до подачи первого ствола;
- τ_4 – время от подачи ствола до локализации пожара;
- τ_5 – время от локализации до ликвидации открытого горения;
- τ_6 – время от ликвидации открытого горения до полной ликвидации последствий.

Статистический анализ показал, что длительности фаз имеют существенную вариативность. Особенно это характерно для фаз активного тушения (τ_4 , τ_5 , τ_6), где коэффициенты вариации достигают значений 3–4, что указывает на наличие тяжелых «правых хвостов» в распределениях. Такая картина типична для процессов, в которых большинство событий происходит относительно быстро, но существует вероятность возникновения экстремальных сценариев с многократным превышением средних значений.

Основная цель калибровки разрабатываемого ЦД – оценить параметры распределений длительностей фаз реагирования и вероятностей переходов между фазами на основе ретроспективных данных.

Важнейшие требования к методу калибровки:

- учёт правосторонней асимметрии и «тяжёлых хвостов» распределений;
- устойчивость при малом числе наблюдений;
- возможность интеграции экспертных знаний;
- получение не только точечных, но и интервальных оценок параметров.

Задача калибровки: на основе наблюдаемых данных о пожарах требуется:

- оценить параметры распределений;
- количественно оценить неопределенность в параметрах;
- обеспечить корректное предсказание экстремальных событий.

На рис. 1 показано сравнение эмпирических данных о длительностях шести последовательных фаз развития пожара с логнормальными распределениями. График демонстрирует плотности вероятности для каждой фазы в диапазоне от 0 до 100 минут, что позволяет визуально оценить характер распределения времени выполнения каждого этапа реагирования. Анализ распределений выявляет четкую дифференциацию фаз по характеру неопределенности. Организационные фазы (1–3) имеют компактные распределения с модой в районе 5–10 минут и быстрым спадом плотности, что свидетельствует о высокой предсказуемости и отработанности процедур. Напротив, оперативные фазы тушения (4–6) демонстрируют выраженную правую асимметрию с «длинными хвостами», достигающими 80–100 минут, что указывает на существенное влияние специфических условий конкретного пожара на рассматриваемых объектах ТЭК и возможность возникновения эскалаций в виде каскадного развития пожара.




Рис.1. Логнормальные распределения длительностей фаз реагирования на пожар

На рис. 2 показана накопительная временная структура процесса пожаротушения в виде каскадной (водопадной) диаграммы, визуализирующей последо-

вательное добавление времени каждой фазы к общей длительности инцидента. Зеленые столбцы представляют приращение времени на каждой фазе, синий столбец показывает итоговую сумму. Такое представление позволяет одновременно видеть, как вклад каждой фазы, так и накопленное время на любом этапе процесса. Диаграмма демонстрирует неравномерность временных затрат по фазам пожаротушения. Организационные фазы (1–3) в сумме занимают 29 минут (28% общего времени), что свидетельствует в целом об эффективности системы оповещения и реагирования. Критическая фаза 4 (подача-локализация) вносит максимальный единичный вклад в 27 минут (26% общего времени), определяя успех всего процесса реагирования. Фазы активного тушения (4–6) суммарно требуют 75 минут (72% времени), что подчеркивает важность технической оснащенности и подготовки личного состава именно для этих этапов. Общее среднее время 104 минуты может служить базовым ориентиром для планирования ресурсов.




Рис.2. Временная динамика развития пожара (каскадная диаграмма)

На рис. 3 показаны коэффициенты логистической регрессии, количественно характеризующие влияние различных неблагоприятных факторов на вероятность задержек при переходе между фазами реагирования. Горизонтальная столбчатая диаграмма ранжирует факторы по силе их негативного воздействия, где большее значение коэффициента β соответствует более существенному увеличению риска задержек. Цветовое кодирование (красный для $\beta > 0,5$, оранжевый для $\beta \leq 0,5$) визуальнo выделяет наиболее критические факторы. Анализ вы-

являет четкую иерархию факторов риска. Неиспользование первичных средств пожаротушения является доминирующим фактором ($\beta = 0,82$), увеличивающим вероятность задержек более чем в два раза. Удаленность объекта от ближайшей пожарно-спасательной части свыше 10 км ($\beta = 0,67$) и отсутствие автоматических установок пожаротушения (далее – АУПТ) ($\beta = 0,45$) формируют второй уровень критичности. Временные факторы (ночное время $\beta = 0,38$) и погодные условия (низкая температура $\beta = 0,29$) оказывают умеренное, но статистически значимое влияние.




Рис.3. Влияние факторов на время фазы локализации пожара

На рис. 4 показано сравнение фактического покрытия 90% предсказательных интервалов для четырех методов калибровки при двух различных объемах обучающей выборки: 150 и 60 наблюдений. Столбчатая диаграмма позволяет визуально оценить устойчивость каждого метода к уменьшению количества доступных данных и его способность поддерживать адекватную калибровку в условиях ограниченной информации. График демонстрирует качество байесовского подхода в условиях ограниченных данных. При уменьшении обучающей выборки с 150 до 60 наблюдений байесовский метод теряет всего 2 процентных пункта покрытия (с 92,6% до 90,6%).




Рис.4. Калибровка предсказательных интервалов

На рис. 5 показано сравнение двух ключевых риск-метрик для общего времени тушения пожара: *Value-at-Risk* (*VaR*), представляющий квантиль распределения, и *Conditional Value-at-Risk* (*CVaR*), показывающий среднее значение в «хвосте» распределения за пределами *VaR*.




Рис.5. Анализ риск-метрик для общего времени тушения пожара

График построен в логарифмическом масштабе по оси времени для

наглядного отображения экспоненциального роста времени в экстремальных сценариях. Расхождение между кривыми VaR и $CVaR$ визуализирует степень тяжести «хвостов» распределения. График демонстрирует критическую важность использования $CVaR$ для планирования ресурсов в системах управления реагированием на пожары. На уровне достоверности 95% $CVaR$ составляет 389 минут, что в 1,8 раза превышает соответствующий VaR (215 минут). Это означает, что в 5% наихудших случаев среднее время тушения составит 6,5 часов, а не 3,6 часа, как можно было бы предположить по квантилю. Экспоненциальный характер роста $CVaR$ на высоких квантилях ($CVaR_{99} = 825$ минут) указывает на возможность катастрофических сценариев длительностью более 13 часов.

Проведенный байесовский анализ 194 пожаров на рассматриваемых объектах ТЭК выявил фундаментальную закономерность: процесс реагирования четко делится на две качественно различные группы фаз. Организационные фазы (обнаружение-сообщение, сообщение-прибытие, прибытие-подача ствола) характеризуются относительной предсказуемостью с коэффициентами вариации 0,8–1,2 и компактными распределениями. Оперативные фазы тушения (подача-локализация, локализация-ликвидация, ликвидация-завершение) демонстрируют высокую вариативность с коэффициентами вариации 3–4 и тяжелыми правыми «хвостами» распределений.

Анализ характеристик распределений выявляет критическую закономерность: вероятность экстремально длительных пожаров существенно выше, чем предсказывают традиционные модели, основанные на нормальном распределении. Логнормальная модель адекватно описывает эмпирическую закономерность, когда 5% пожаров длятся в 3–4 раза дольше медианного времени. Это объясняется мультипликативным характером воздействия неблагоприятных факторов: каждый дополнительный осложняющий фактор не добавляет фиксированное время, а увеличивает общую длительность в определенное число раз.

Установлена иерархическая структура влияния факторов на динамику пожаротушения (фазы 4–6). Технические факторы готовности (наличие первичных средств пожаротушения, АУПТ) оказывают доминирующее влияние с коэффи-

циентами 0,45–0,82, пространственные факторы (удаленность от ПСЧ) занимают промежуточное положение с коэффициентом 0,67, а факторы (время суток, погода) имеют умеренное влияние с коэффициентами 0,29–0,38. Эта закономерность указывает на приоритет превентивных мер технического характера над организационными улучшениями.

Байесовская калибровка также важную закономерность: неопределенность в параметрах модели неравномерно распределена по фазам. Наибольшая параметрическая неопределенность наблюдается для фазы локализации ($\sigma(\mu_4) = 0,15$), что отражает критическую роль специфических условий конкретного пожара именно на этом этапе. При этом байесовский подход демонстрирует устойчивость: даже при сокращении обучающей выборки с 150 до 60 наблюдений качество калибровки предсказательных интервалов деградирует всего на 2%.

Выявленные закономерности подтверждают научную основу для риск-ориентированного подхода к управлению пожарной безопасностью объектов ТЭК. Доминирование оперативных фаз в общем времени (72%) и их высокая вариативность обосновывают необходимость планирования ресурсов не по средним, а по *CVaR*-метрикам. Установленная иерархия факторов влияния позволяет оптимизировать инвестиции в системы обеспечения пожарной безопасности, приоритизируя технические системы раннего обнаружения и первичного пожаротушения. Логнормальный характер распределений с «тяжелыми хвостами» требует создания резервных мощностей, рассчитанных на экстремальные сценарии с длительностью в 6–13 часов, возникающие в 5–1% случаев соответственно.

Заключение и выводы

1. Байесовская калибровка обеспечивает статистически корректное и практически применимое решение задачи параметризации ЦД процессов реагирования пожарно-спасательных подразделений. Преимущество перед классическими методами особенно выражено в условиях ограниченных данных и при необходимости моделирования редких экстремальных событий (затяжных пожаров).

2. Разработанная методика готова к внедрению в СППР. Ключевые мет-

рики качества (покрытие $> 90\%$, ошибка $Q_{9.5} < 5\%$) удовлетворяют современным требованиям в области управления безопасностью.

3. Логнормальная модель с байесовской калибровкой адекватно описывает эмпирические закономерности развития пожаров на рассмотренных объектах ТЭК, учитывая как типичные сценарии, так и катастрофические события с многократным превышением средних значений.

4. Дальнейшее совершенствование модели может включать учет пространственно-временных корреляций, иерархическое моделирование для объектов различных классов опасности, а также интеграцию с физическими моделями распространения пожара для создания гибридных ЦД.

Список литературы

1. Орлова, Е. В. Методическое обеспечение разработки цифровых двойников организационных систем / Е. В. Орлова // Математическое и компьютерное моделирование в экономике, страховании и управлении рисками. – 2022. – № 7. – С. 243–247.
2. Дурнев, Р. А. Экспертная система технико-экономической оценки целесообразности применения технологии цифровых двойников на различных этапах жизненного цикла аварийно-спасательной техники / Р. А. Дурнев, И. В. Жданенко, Е. В. Свиридок // Проблемы анализа риска. – 2024. – Т. 21, № 2. – С. 42–53.
3. Репина, И. Б. К вопросу о конкурентоспособности цифровых платформ по внедрению цифровых двойников / И. Б. Репина, Н. Г. Сидорова, О. А. Чуднова [и др.] // Проблемы теории и практики управления. – 2024. – № 7–8. – С. 73–88.
88. Сергеев П.В. Идентификация гидродинамических исследований скважин / П.В. Сергеев, В.Л. Сергеев // Вычислительные технологии. — 2005. — Т.21. — № 2. С.125 – 129.
3. Садовский М.Г. Оптимизационные модели миграции глобально информированных особей / М.Г. Садовский // В: Математическое моделирование в биологии и химии. Эволюционный подход. Ред. Р.Г. Хлебопрос. — Новосибирск: Наука. — 1992. — С.36 – 67.

4. Хабибулин, Р. Ш. Структура и порядок создания цифрового статистического двойника в системах поддержки управления пожарной безопасностью объектов ТЭК / Р. Ш. Хабибулин // Современные проблемы обеспечения безопасности: Сборник материалов XXVII Международной научно-практической конференции, Екатеринбург, 24–25 апреля 2025 года. – Екатеринбург: Уральский институт Государственной противопожарной службы МЧС России, 2025. – С. 150–155.

СПИСОК ДОКЛАДОВ

Н.М. Богатов, А.Н. Богатова, А.Л. Еремин, С.А. Сухих ФРАКТАЛЬНЫЕ ПАРАМЕТРЫ ИЗМЕНЕНИЯ ПСИХОФИЗИОЛОГИЧЕСКИХ ПОКАЗАТЕЛЕЙ В РЕЗУЛЬТАТЕ САМОРЕГУЛЯЦИИ	3
А.В. Волоснев, П.В. Гуров, И.А. Абрамов, А.С. Родченко, В.И. Горбаченко ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ПАРАМЕТРОВ БУРЕНИЯ НЕФТЕГАЗОВОЙ СКВАЖИНЫ	14
С.Е. Головенкин, И.В. Савицкий ПРИМЕНЕНИЕ МЕТОДА УПРУГИХ (ЭЛАСТИЧНЫХ) КАРТ ДЛЯ ВИЗУАЛИЗАЦИИ ДАННЫХ В КАРДИОЛОГИИ	24
М.Г. Доррер РАЗРАБОТКА НЕЙРОСЕТЕВОЙ ПРОГНОСТИЧЕСКОЙ МОДЕЛИ ЦИФРОВОГО ДВОЙНИКА ПОКАЗАТЕЛЕЙ БИЗНЕС-ПРОЦЕССОВ	28
М.Г. Ерунова, О.Э. Якубайлик, А.А. Кадочников, М.Ю. Сенашова КЛАСТЕРИЗАЦИЯ ВОДОСБОРОВ ЧЕТЫРЕХ РЕК КРАСНОЯРСКОГО КРАЯ НА ОСНОВЕ ДЗЗ	42
А.М. Корсаков, В.В. Иванова, А.А. Демчева НЕЙРОМОРФНАЯ СИСТЕМА НАВИГАЦИИ ДЛЯ АВТОНОМНЫХ МОБИЛЬНЫХ РОБОТОВ	56
Г.М. Маркова, С.И. Барцев ПРЕДСКАЗУЕМОСТЬ СОБЫТИЙ В ПРЕДЕЛЬНЫХ МОДЕЛЯХ МИРА ВЛИЯЕТ НА ФОРМИРОВАНИЕ	

УНИВЕРСАЛЬНОГО НАВЫКА РЕФЛЕКСИИ	65
Д.Н. Наталенко	
МНОГОУРОВНЕВОЕ АДАПТИВНОЕ ВОССТАНОВЛЕНИЕ ИНФРАКРАСНЫХ ИЗОБРАЖЕНИЙ ДИКИХ ЖИВОТНЫХ	76
N. Nishchhal	
QUALITY METRICS FOR MRI-CT FUSION IN ABDOMINAL IMAGING: A NOVEL HYPOTHESIS FOR EVALUATION	86
Б.В.Олейников, А.В.Пакулев	
ПРОГНОЗИРОВАНИЕ БИОТИЧЕСКИХ ВРЕМЕННЫХ РЯДОВ С УЧЁТОМ ВНЕШНЕГО ФАКТОРА	93
М.В.Савков	
МЕТОД НЕКОНТРОЛИРУЕМОГО СОЗДАНИЯ ПОДПИСИ К ИЗОБРАЖЕНИЮ ДЛЯ ЗАДАЧИ ПОВТОРНОЙ ИДЕНТИФИКАЦИИ ЧЕЛОВЕКА	102
Н.В.Саидов	
ОБНАРУЖЕНИЕ ЗАМАСКИРОВАННЫХ ОБЪЕКТОВ НА ИЗОБРАЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ ДИФФУЗИОННЫХ МОДЕЛЕЙ НА ОСНОВЕ КАРТ НЕОПРЕДЕЛЁННОСТИ	112
Г.А. Смирнов, А.Д. Пронин, М.В. Кузнецов, В.А. Углев	
МЕХАНИЗМЫ РАБОТЫ ИНТЕЛЛЕКТУАЛЬНОЙ АВТОМАТИЗИРОВАННОЙ ОБУЧАЮЩЕЙ СИСТЕМЫ AESU	121
И.Е. Старостин	
АРХИТЕКТУРА ФИЗИЧЕСКИ-ИНФОРМИРОВАННЫХ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ЭНЕРГЕТИЧЕСКИХ ПРОЦЕССОВ	132

М.Н. Фаворская

КРОСС-ДОМЕННОЕ ОБУЧЕНИЕ НА МАЛЫХ ВЫБОРКАХ
ДЛЯ ЗАДАЧИ СЕГМЕНТАЦИИ МЕДИЦИНСКИХ СНИМКОВ 141

И.С. Фомин, А.И. Андреев

ИССЛЕДОВАНИЕ КАЧЕСТВА И ПРОИЗВОДИТЕЛЬНОСТИ
РАБОТЫ АЛГОРИТМОВ СЕМЕЙСТВА YOLO В ЗАДАЧЕ
РАСПОЗНАВАНИЯ ОБЪЕКТОВ МАЛЫХ РАЗМЕРОВ 147

Р.Ш. Хабибулин

БАЙЕСОВСКАЯ КАЛИБРОВКА ЦИФРОВОГО ДВОЙНИКА
РЕАГИРОВАНИЯ ПОЖАРНО-СПАСАТЕЛЬНЫХ ПОДРАЗДЕЛЕНИЙ
НА ОСНОВЕ РЕТРОСПЕКТИВНЫХ ДАННЫХ 155

СПИСОК АВТОРОВ

ФИО	Место работы	Стр.
Абрамов Игорь Анатольевич	440026, г. Пенза, ул. Красная, 40, Пензенский государственный университет E-mail: igora379@gmail.com	14
Андреев Александр Иванович	195251, Санкт-Петербург, Политехническая ул., 29, СПбПУ E-mail: Anderaleksander@yandex.ru	147
Барцев Сергей Игоревич	660036, Красноярск, ул. Академгородок, строение 50, Институт биофизики СО РАН E-mail: bartsev@yandex.ru	65
Богатов Николай Маркович	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: bogatov@phys.kubsu.ru	3
Богатова Анна Николаевна	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: anna_bogatova@mail.ru	3
Волоснев Антон Викторович	127254, г. Москва, АО «Дриллматик» E-mail: av@drillmatic.ru	14
Головенкин Сергей Евгеньевич	660022, Красноярск, ул. Партизана Железняка, 1, ФГБОУ ВО «Красноярский Государственный Ме-дицинский Университет им. проф. В.Ф.Войно-Ясенецкого» МЗ РФ, E-mail: gse2008@mail.ru	24
Горбаченко Владимир Иванович	440026, г. Пенза, ул. Красная, 40, Пензенский государственный университет E-mail: gorvi@mail.ru	14
Гуров Павел	127254, г. Москва, АО «Дриллматик»	14

Владимирович	E-mail: pg@drillmatic.ru	
Демчева Александра Андреевна	194064, Санкт-Петербург, Тихорецкий пр., д. 21, Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК) E-mail: a.demcheva@rtc.ru	56
Доррер Михаил Георгиевич	660000, Красноярск, просп. Имени газеты Красноярский Рабочий, 31, Сибирский государственный университет науки и технологий им. М.Ф. Решетнева E-mail: dorrer_mg@sibsau.ru	28
Еремин Алексей Львович	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: aereimin@yandex.ru	3
Ерунова Марина Геннадьевна	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: marina@icm.kras.ru	42
Иванова Виктория Владимировна	194064, Санкт-Петербург, Тихорецкий пр., д. 21, Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК) E-mail: v.ivanova@rtc.ru	56
Кадочников Алексей Анатольевич	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: scorant@icm.krasn.ru	42

Корсаков Антон Михайлович	194064, Санкт-Петербург, Тихорецкий пр., д. 21, Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК) E-mail: a.korsakov@rtc.ru	56
Кузнецов Михаил Владимирович	662971, Красноярский край, Железногорск, ул. Кирова, 12-а, СФУ E-mail: kurt21.89@mail.ru	121
Маркова Галия Муратовна	660036, Красноярск, ул. Академгородок, строение 50, Институт биофизики СО РАН E-mail: irvingstone@bk.ru	65
Наталенко Дмитрий Николаевич	660037, г. Красноярск, проспект им. газеты Красноярский рабочий, 31, ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева» E-mail: dmitriy.natalenko@mail.ru	76
Нишчхал Н.	660037, г. Красноярск, пр. им. газеты Красноярский рабочий, 31, проспект Мира, 82, Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева E-mail: Nik.321g@yandex.ru	86
Олейников Борис Васильевич	660041, Красноярск, пр. Свободный, 79, Сибирский федеральный университет E-mail: oleynik4810@gmail.com	93
Пакулев Андрей Валерьевич	660041, Красноярск, пр. Свободный, 79, Сибирский федеральный университет E-mail: vitamin1235@yadex.ru	93
Пронин Артём Дмитриевич	662971, Красноярский край, Железногорск, ул. Кирова, 12-а, СФУ E-mail: artempronin96@list.ru	121

Родченко Александр Сергеевич	440026, г. Пенза, ул. Красная, 40, Пензенский государственный университет E-mail: rodchenko-aleksandr01@mail.ru	14
Савков Максим Вениаминович	660037, г. Красноярск, проспект им. газеты Красноярский рабочий, 31, ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева» E-mail: msavkov2017@gmail.com	102
Савицкий Иван Владимирович	660022, Красноярск, ул. Партизана Железняка, 1, ФГБОУ ВО «Красноярский Государственный Медицинский Университет им. проф. В.Ф.Войно- Ясенецкого» МЗ РФ, E-mail: idontknown@mail.ru	24
Саидов Назар Викторович	660037, г. Красноярск, проспект им. газеты Красноярский рабочий, 31, ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева» E-mail: nazar-saidov1999@mail.ru	112
Сенашова Мария Юрьевна	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: msen@icm.krasn.ru	42
Смирнов Георгий Артёмович	660074, Красноярск, ул. Академика Киренского, 26Б, ИКИТ СФУ E-mail: determaer2012@gmail.com	121
Старостин Игорь Евгеньевич	125993, г. Москва, Кронштадтский бульвар, д. 20 Московский государственный технический университет гражданской авиации E-mail: starostinigo@yandex.ru	132

Суших Станислав Алексеевич	350040, г. Краснодар, ФГБОУ ВО «Кубанский государственный университет», ул. Ставропольская, 149 E-mail: suhih_52@mail.ru	3
Углев Виктор Александрович	662971, Красноярский край, Железногорск, ул. Кирова, 12-а, СФУ E-mail: uglev-v@yandex.ru	121
Фаворская Маргарита Николаевна	660014, Красноярск, пр. имени газеты «Красноярский рабочий», 31, Сибирский государственный универси-тет науки и технологий имени акад. М.Ф. Решетнева E-mail: favorskaya@sibsau.ru	141
Фомин Иван Сергеевич	194064, Санкт-Петербург, Тихорецкий пр., 21, ЦНИИ РТК E-mail: Aivan_2008@mail.ru	147
Хабибулин Ренат Шамильевич	129366, г. Москва, ул. Бориса Галушкина, д. 4, Академия Государственной противопожарной службы МЧС России E-mail: kh-r@yandex.ru	155
Якубайлик Олег Эдуардович	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: oleg@icm.krasn.ru	42

Научное издание

Нейроинформатика, её приложения и анализ данных

Материалы XXXIII Всероссийского семинара 26 сентября 2025 года

Редактор М.Ю. Сенашова
Компьютерная верстка: М.Ю. Сенашова

Подписано в печать «15» августа 2025 г. Формат 60 × 90/8. (А4)
Бумага офсетная. Печать плоская.
Усл. печ. л. 11,0. Уч.-изд. л. 9,2.
Тираж 50 экз. Заказ 11