

Нейроинформатика, её приложения и анализ данных

XXXIV Всероссийский семинар

**Красноярск
2026**

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 ЧЕТВЕРТОГО ВСЕРОССИЙСКОГО СЕМИНАРА
25 сентября 2026 года

Красноярск 2026

УДК 007.52 (042.3)

Н 43

Нейроинформатика, её приложения и анализ данных: Материалы XXXIV Всероссийского семинара, 25 сентября 2026 года / Под ред. О.Э. Якубайлика, отв. за вып. М.Ю. Сенашова; – Красноярск: Институт вычислительного моделирования СО РАН, 2026. – 133 с.

В сборнике представлены материалы XXXIV Всероссийского семинара «Нейроинформатика, её приложения и анализ данных», проходившей в городе Красноярске 25 сентября 2026 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 № 075-02-2026-735).

Редакционная коллегия:

Якубайлик Олег Эдуардович – ответственный редактор

Сенашова Мария Юрьевна – ответственный за выпуск

© ИВМ СО РАН, 2026

© Коллектив авторов, 2026

ISBN 978-5-6054684-3-1



9 785605 468431 >

КЛЕТОЧНО-АВТОМАТНАЯ МОДЕЛЬ ХИМИЧЕСКОЙ СООРГАНИЗАЦИИ КЛЕТОК С ДИФFUЗНОЙ ПЕРЕДАЧЕЙ НЕЙРОМЕДИАТОРОВ

Е.Е. Баранчикова^{1,2}, С.И. Барцев^{1,2}

¹Сибирский федеральный университет,

Институт фундаментальной биологии и биотехнологии, каф. биофизики

²Институт биофизики СО РАН, *katia.krasnoyarsk@yandex.ru*

Живые системы способны без централизованного управления формировать различные структуры и демонстрировать сложные формы поведения [1]. Например, в процессе эмбрионального развития множество клеток, взаимодействуя друг с другом и с окружающей средой, формируют сложную структуру организма. При этом отдельная клетка не располагает информацией о состоянии всей системы, а реагирует преимущественно на изменения в своем непосредственном окружении. Таким образом, организация многоклеточной системы может возникать как результат множества локальных взаимодействий между отдельными клетками.

Особый интерес представляет способность клеток к организации посредством только химической передачи сигналов. Согласно одной из гипотез происхождения нервной системы, классические нейроны эволюционировали из секреторных клеток, использовавших только химическую передачу сигналов [2].

Trichoplax adhaerens, представитель типа *Placozoa*, не имея нервной системы, способен воспринимать изменения окружающей среды и в ответ на них изменять своё поведение [3]. Он представляет собой двуслойную пластину, состоящую из шести типов клеток. Вентральная поверхность покрыта жгутиками, с помощью которых трихоплакс перемещается по поверхностям в поиске пищи.

Механизмом взаимодействия клеток в трихоплаксе является химическая передача сигналов. Сигнальные молекулы, выделенные одной клеткой, распространяются посредством диффузии в межклеточном пространстве. Таким образом, формируется локальный сигнал, который улавливается соседними клетками. Множество таких сигналов и реакция на них формируют сложное поведение системы без централизованного управления.

Изучение этих механизмов позволит исследовать принципы организации клеток и может быть использовано при разработке моделей самоорганизующихся систем и искусственных нейронных сетей.

Целью работы являлась разработка алгоритма химической соорганизации клеток для моделирования пищевого поведения *Trichoplax adhaerens*. Была разработана клеточно-автоматная модель, в которой пищевое поведение организма формируется на основе локальных химических сигналов и взаимодействия клеток.

Перемещение организма в естественных условиях обеспечивается согласованным движением жгутиков клеток вентральной поверхности. В модели это движение представлено перемещением отдельных клеток, каждая из которых может двигаться в любом направлении. Для сохранения целостности организма взаимодействие между клетками задавалось с помощью метода позиционной динамики.

Каждая клетка модели представляет собой конечный автомат – математическую модель, обладающую конечным набором состояний и набором правил переходов. В текущей реализации модели используется два типа клеток: краевые и внутренние. Только краевые клетки имеют рецепторы специфичные к аттрактанту. Для распространения информации между клетками используется внутренне сигнальное вещество, улавливаемое всеми типами клеток.

Информация от рецепторов, расположенных на мембране, передается внутрь клетки на конечный автомат в виде типа воспринимаемого сигнала — аттрактанта или внутреннего сигнального вещества — и значения мембранного потенциала в области рецептора. При достижении мембранным потенциалом порогового значения клетка переходит в активное состояние и начинает движение в направлении источника сигнала. При этом она выбрасывает внутреннее сигнальное вещество в направлении противоположном от направления движения. Таким образом, соседние клетки получают информацию о направлении, откуда поступил исходный сигнал. Информация о местоположении источника пищи последовательно передается от краевых клеток к внутренним, формируя волну химической активности, распространяющуюся по организму.

После активации клетка переходит в состояние релаксации, при котором мембранный потенциал ниже, чем в состоянии покоя. Такая клетка два такта времени не воспринимает сигнальные вещества. После этого потенциал начинает восстанавливаться до значения покоя, и клетка переходит в неактивное состояние. В неактивном состоянии клетка совершает движение в случайном направлении, что обеспечивает локальные флуктуации положения организма в отсутствии аттрактанта, которые наблюдаются и у живых трихоплаксов [4].

В работе Carolyn L. Smith и др. [5] было показано, что поведение живых трихоплаксов зависит от расстояния до источника пищи. На удалении от источника трихоплакс осуществляет случайный поиск, сопровождающийся частыми изменениями направления движения. При приближении к пище движение становится направленным к источнику.

Для формирования случайного блуждания при длительном отсутствии аттрактанта в модельном трихоплаксе происходит активация случайной краевой клетки в течение некоторого интервала времени. Такая клетка играет роль пейсмейкера, задающего направление движения организма. Если некоторый случайный интервал времени организм не обнаруживает аттрактант, то на роль пейсмейкера назначается другая случайная краевая клетка. Это происходит до тех пор, пока аттрактант не будет обнаружен.

Полученные в ходе работы траектории движения модельного трихоплакса (рисунок 2) сравнивались с траекториями движения восьми особей живых трихоплаксов в присутствии локализованного источника пищи (рисунок 1).

Данные перемещений живых трихоплаксов были получены в результате обработки видео, взятого из работы Carolyn L. Smith и др. [5], с помощью программы Fiji ImageJ [6].

Длительность видео составляет 7 часов 20 минут. Для анализа движения из него были отобраны 120 кадров через каждые 220 секунд.




Рис.1. Траектории движения живых трихоплаксов




Рис.2. Траектории движения модельного трихоплакса

На рисунке 2 красной точкой отмечено положение организма в момент первой активации клеток аттрактантом. Черной точкой отмечено, откуда начал свое движение трихоплакс. Жёлтой – конечная точка траектории. Размер организма – 37 клеток.

Как у живых, так и у модельного трихоплаксов начальный этап движения характеризуется сложной траекторией с многочисленными изменениями направления движения и небольшими петлями. По мере приближения к пищевому объекту движение становится более направленным к источнику.

На рисунке 3 показано изменение расстояния до источника пищи во времени для живых трихоплаксов. В первые 130 минут наблюдения особи демонстрируют низкую двигательную активность, совершая лишь короткие перемещения и вращения. Такое поведение может быть обусловлено адаптацией организма к новым условиям среды. В работе Михаила Никитина и соавторов 2023 года [4] отмечается, что в новой среде трихоплаксы в течение первых двух часов проявляют пониженную активность, после чего начинается постепенное увеличение скорости движения.




Рис.3. Графики изменения расстояния до еды во времени при движении живых трихоплаксов

На рисунке 4 представлены графики изменения расстояния до еды во времени при движении модельного трихоплакса. И у живых трихоплаксов, и у модельного наблюдается переход от поиска к направленному движению, сопровождающийся резким уменьшением расстояния до источника пищи. Этот переход происходит на некотором расстоянии от источника. Момент перехода отмечен на графиках черной точкой (рисунки 3, 4). Для его определения рассчитывалась первая производная сглаженной зависимости расстояния до пищи от времени. В качестве момента перехода принималась точка, в которой первая производная становилась отрицательной, что соответствует началу устойчивого уменьшения расстояния до пищи.




Рис. 4. Графики изменения расстояния до еды со временем при движении модельного трихоплакса

В работе Михаила Никитина и соавторов [4] показано, что в траектории движения трихоплакса присутствуют участки колебательного характера, в пределах которых организм некоторое время находится вблизи одной точки и совершает вращательные движения (рисунок 5). На этих участках динамика перемещения становится более хаотичной и похожей на броуновское движение.




Рис.5. Участки колебательного движения в траектории биологического трихоплакса

Модель, представленная в работе, также имеет аналогичные области колебательного движения (рисунок 6). Они обеспечиваются короткими периодами отсутствия в системе пейсмейкера, во время которых клетки, находясь в неактивном состоянии, совершают движения в случайных направлениях.




Рис. 6. Участки колебательного движения в траектории модельного трихоплакса

Сопоставление результатов моделирования с траекториями движения живых трихоплаксов показало сходство характерных паттернов поискового и пищевого поведения.

Таким образом, можно утверждать, что разработанный алгоритм химической организации клеток воспроизводит пищевое поведение *Trichoplax adhaerens*. Полученные результаты демонстрируют возможность формирования в виртуальной среде согласованного поведения клеточной системы на основе локального химического взаимодействия без централизованного управления.

Список литературы

1. McMillen P. Collective intelligence: A unifying concept for integrating biology across scales and substrates / P. McMillen, M. Levin // *Communications Biology*. — 2024. — Vol.7. — Article 378.
2. Мороз Л.Л. Генеалогия нейронов: 50 лет реконструкции эволюции нервных систем / Л.Л. Мороз, В.Е. Дьяконова // *Онтогенез*. — 2024. — Т. 55. — № 2. — С. 75–86.
3. Bechtel W. Eating and Cognition in Two Animals without Neurons: Sponges and Trichoplax / W. Bechtel, L. Bich // *Biological Theory*. — 2024.
4. Nikitin M.A. Amino acids integrate behaviors in nerveless placozoans / M.A. Nikitin, D.Y. Romanova, S.I. Borman, L.L. Moroz // *Frontiers in Neuroscience*. — 2023. — Vol. 17.
5. Smith C.L. Coherent Directed Movement toward Food Modeled in Trichoplax, a Ciliated Animal Lacking a Nervous System / C.L. Smith, W.M. Pivonka, S. Vyas, T.S. Reese, R. Prakash // *Proceedings of the National Academy of Sciences of the United States of America*. — 2019. — Vol. 116. — P. 8901–8908.
6. Schindelin J. Fiji: an open-source platform for biological-image analysis / J. Schindelin, I. Arganda-Carreras, E. Frise // *Nature Methods*. — 2012. — Vol. 9. — P. 676–682.

НЕЙРОННО-ИНФОРМАЦИОННЫЕ ПРОЦЕССЫ В МОЗГЕ

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

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

Моделирование информационных процессов в мозге – одно из современных направлений нейробиологии. Электрохимическая модель нервного импульса создана в работах Ходжкина, Хаксли с сотрудниками [1, 2]. Эта модель успешно объясняет и предсказывает распространения потенциала действия (ПД) в немиелинизированных аксонах. Для объяснения сальтаторной проводимости в миелинизированной оболочке используются физико-математические модели распространения (ПД) на основе теории солитонов [3, 4], распространения электромагнитных волн (ЭМВ) через волновод [5, 6], внутриклеточных электрических полей [7], квантово-ограниченной ионной сверхтекучести [8], клеточного вибронного поляритона [9], молекулы воды на поверхности нейрона [10].

Особый интерес представляют исследования эфаптических взаимодействий (ЭВ) при распространении импульсов в среде, содержащей аксоны. Концепция ЭВ основана на том, что внеклеточный потенциал (ВП) влияет на распространение ПД. Показано, что ВП изменяет скорость распространения ПД [11] и синхронизирует генерацию импульсов [12]. Природу ЭВ объясняют суперпозицией статических электрических полей, созданных зарядовыми диполями в ионных каналах мембраны перехватов Ранвье [13], электродинамическими свойствами мембраны и существованием внеклеточных волновых форм [14], электромагнитными полями [15], созданными электрическим током в нервном волокне. Экспериментально показано, что ЭВ вызывает изменения соматического мембранного потенциала [16], коррелированную активность клеток Пуркинье мозжечка [17]. ПД может быть вызван контролируемым приложением внешнего электрического поля [18]. Слабые внеклеточные электрические поля определяют направление роста нейритов [19]. Электрические поля, генерируемые нейронами, имеют причинно-следственную связь вплоть до уровня цитоскелета [20]. В обзорной статье [21] обсуждаются возможные механизмы взаимовлияний на дендритную деполяризацию пассивных и активных свойств дендритного дерева. Для анализа распространения сигнала в нервном волокне используются модифицированные кабельные модели [22 – 27]. Таким образом, природа ЭВ является сложной и содержит не изученные до конца механизмы.

Цель исследования – анализ электромагнитных процессов при распространении сигнала в нейроне.

Объект исследования – аксон, покрытый миелиновой оболочкой, разделённой перехватами Ранвье.

Предмет исследования – электромагнитное поле.

Распространение ПД $V(x, t)$ вдоль нервного волокна с учетом генерации потенциала на каждом участке волокна описывается обобщенным уравнением [27]:

$$\frac{r_k}{2\rho_{ak}} \frac{\partial^2 V_k}{\partial x^2} - C_{mk} \frac{\partial V_k}{\partial t} - \frac{V_k}{\rho_{mk} l_k} + \frac{G_k(x, t)}{2\pi r_k} = 0, \quad (1)$$

где r_k – радиус аксона, ρ_{ak} – удельное сопротивление аксоплазмы, C_{mk} – электрическая емкость единицы площади мембраны, ρ_{mk} – удельное сопротивление вещества мембраны, l_k – толщина мембраны, G_k – скорость генерации заряда на единицу длины волокна. Индекс $k = 1, 2$ нумерует области аксона: 1 – перехват Ранвье длиной L_1 , 2 – область, покрытая миелином длиной L_2 . Пара областей 1 и 2 периодически повторяется. Потенциал действия отсчитывается от потенциала покоя V_{rk} . Потенциал зависимые ионные каналы равномерно распределены по поверхности в каждом сечении волокна. Краевые условия для уравнения (1) задаются на границах областей $x_1 \in [0, L_1]$, $x_2 \in [L_1, L_2]$.

Введем безразмерные переменные

$$x'_k = \frac{x}{\lambda_k}, \quad t'_k = \frac{t}{\tau_k}, \quad V'_k = \frac{V}{|V_{rk}|}, \quad G'_k = \frac{\rho_{mk} l_k G_k}{2\pi r_k |V_{rk}|}, \quad \lambda_k = \sqrt{\frac{r_k l_k \rho_{mk}}{2\rho_{ak}}}, \quad \tau_k = l_k \rho_{mk} C_{mk} \quad (2)$$

В безразмерных переменных уравнение (1) принимает вид

$$\frac{\partial^2 V'_k}{\partial x'^2_k} - \frac{\partial V'_k}{\partial t'_k} - V'_k + G'_k(x'_k, t'_k) = 0. \quad (3)$$

Решаем уравнение (3) методом [27].

$$V'_k(x'_k, t'_k) = \int_{-\infty}^{\infty} U_k(\nu') e^{\alpha_k(\nu') x'_k} e^{2\pi i \nu' t'_k} d\nu', \quad G'_k(x'_k, t'_k) = \int_{-\infty}^{\infty} F_k(\nu') e^{\alpha_k(\nu') x'_k} e^{2\pi i \nu' t'_k} d\nu' \quad (4)$$

В перехвате Ранвье решение уравнения (3) имеет вид

$$V'_1(x'_1, t'_1) = \int_{-\infty}^{\infty} \left[-\frac{F_1(\nu') x'_1}{2\alpha_1(\nu')} + V_{01}(\nu') \right] e^{\alpha_1(\nu') x'_1} e^{2\pi i \nu' t'_1} d\nu', \quad (5)$$

где

$$V_{01}(t) = \int_{-\infty}^{\infty} V_{01}(\nu') e^{2\pi i \nu' t'_1} d\nu',$$

$$\operatorname{Re} \alpha_1(\nu') = \frac{\pi \nu'}{\operatorname{Im} \alpha_1(\nu')} < 0, \quad \operatorname{Im} \alpha_1(\nu') = \begin{cases} -\frac{1}{2} \sqrt{\sqrt{1 + (2\pi \nu')^2} - 1}, & \nu' \geq 0 \\ \frac{1}{2} \sqrt{\sqrt{1 + (2\pi \nu')^2} - 1}, & \nu' < 0 \end{cases}, \quad (6)$$

Решение (5) является импульсом, распространяющимся в направлении оси X . Фазовая скорость импульса [27]

$$v_k = \frac{1}{C_{mk}} \sqrt{\frac{2r_k}{l_k \rho_{mk} \rho_{ak}}} . \quad (7)$$

В области, покрытой миелином, решение имеет аналогичный вид, но условия транспорта носителей заряда другие. Миелиновая оболочка – это концентрически слоистая мембранная структура, образующая плотную упаковку (~100 слоев) вокруг аксона. Миелин изолирует аксон, т.к. образует диэлектрическую оболочку. Миелиновая оболочка уменьшает скорость генерации заряда, $G_2 \approx 0$, т.к. отсутствуют потенциалзависимые ионные каналы. Электрическая емкость миелиновой оболочки много меньше, чем мембраны перехвата Ранвье, $C_{m2} \sim C_{m1}/100$, но толщина во столько же раз больше. Миелин содержит много холестерина и мало белка, поэтому его удельное сопротивление ρ_{m2} выше удельного сопротивления мембраны ρ_{m1} . Это обеспечивает увеличение скорости импульса в слое миелина более, чем в 10 раз.

Генерация электрического импульса в перехвате Ранвье обуславливает изменение компоненты напряжённости электрического поля в радиальном направлении, перпендикулярном оси аксона, $|E(x_1, t_1)| \sim V_1(x_1, t_1)/l_1$. Электрическое поле, возникшее в одном перехвате Ранвье, генерирует заряд в соседнем перехвате Ранвье через потенциалзависимые ионные каналы, таким образом, электрический импульс распространяется скачкообразно (сальтаторно) от одного перехвата к другому.

Электрический ток в перехвате Ранвье и переменное во времени электрическое поле порождают вихревое магнитное поле, а изменение магнитного поля порождает вихревое электрическое поле

$$\text{rot } \vec{H} = \frac{\partial \vec{D}}{\partial t} + \vec{j} , \quad \text{rot } \vec{E} = - \frac{\partial \vec{B}}{\partial t} .$$

где $\vec{H}$ – вектор напряжённости магнитного поля, $\vec{B}$ – вектор индукции магнитного поля, $\vec{E}$ – вектор напряжённости электрического поля, $\vec{D}$ – вектор индукции электрического поля, $\vec{j}$ – вектор плотности электрического тока. Таким образом, возникает внешнее по отношению к аксону электромагнитное поле (ЭМП), участвующее в эфаптических взаимодействиях. Учитывая периодичность повторения пары перехват Ранвье - миелинизованная область, можно говорить об электромагнитной волне, распространяющейся вне аксона. Внешнее ЭМП гиперполяризует или деполяризует потенциалзависимые ионные

каналы, что при достижении порога генерации может вызывать потенциал действия в перехватах Ранвье как исходного, так и соседних аксонов.

Для описания сложного полевого взаимодействия на уровне организма в целом используется теория фракталов. В работе [28] 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.

Следует отметить историю развития теоретических основ приложений теории фракталов и автономности, в том числе к биологическим системам, дающих начало полевой интерпретации. В начале XX века основы изучения «комплексной динамики» были заложены множеством Жюлиа [29] и множеством Фату [30] – два дополняющих друг друга множества, определяемые с помощью функции. Множество Фату функции состоит из значений, для которых все близлежащие значения ведут себя одинаково при многократном повторении функции, а в множестве Жюлиа малое возмущение может вызвать резкие изменения в последовательности повторяющихся значений функции. Поведение функции на множестве Фату является «регулярным», а на множестве Жюлиа — «хаотичным». Множество Жюлиа функции f обычно обозначается $J(f)$, а множество Фату – $F(f)$.

К концу XX века «фрактальное поведение», связанное с итеративными функциями было определено в работах Мандельброта [31] и в дальнейшем развито многими учеными [32]. Для формализации «автономности» Варелой было предложено выражение $F = f(F)$, где F – любые процессы, взаимодействия, реорганизации, а f – форма отношений между этими процессами, форма их взаимозависимости. Выражение названо точно зафиксированной репрезентацией, самореферентным (кругообразным, бесконечно рекурсивным), лежащим в основе механизма автономности [32, 33].

В [34] для анализа изменения физиологических и психофизиологических показателей в результате процессов саморегуляции используется фрактальная интерпретация. Под фракталом понимается структура, строящаяся из самоподобных элементов, но не имеющих заданной геометрической формы. Устойчивый или квазиустойчивый фрактал реализуется посредством самосогласованного взаимодействия биологических структур, включающего электрические, электромагнитные, акустические, механические, химические и другие процессы. Обозначая совокупность свойств организма, используется

термин психофизический фрактал (ПФФ), имеющий как геометрическую, так и полевую структуру.

Список литературы

1. Hodgkin A.L. The electrical constants of a crustacean nerve fibre / A.L. Hodgkin, W.A.H. Rushton // *Proc. Roy. Soc.* — 1946. — Ser B. — V. 133. — P. 444 – 479.
2. Hodgkin A.L. A quantative description of membrane current and its application to conduction and excitation in nerve / A.L. Hodgkin, A.F. Huxley // *J. Physiol.* — 1952. — V. 117. — N. 4. — P. 500 – 544.
3. Максименко Е.В. Моделирование распространения нервного импульса с использованием ЭВМ / Е.В. Максименко // *Обозрение прикладной и промышленной математики.* — 2004. — Т. 11. — В.2. — С. 368 – 369.
4. Максименко Е.В. Об использовании математических методов в биологических исследованиях / Е.В. Максименко // *Обозрение прикладной и промышленной математики.* — 2005. — Т. 12. — В. 2. — С. 431 – 432.
5. Zhai Qing-Wei. Long range electromagnetic field nature of nerve signal propagation in myelinated axons / Qing-Wei Zhai, Kelvin J.A. Ooi, Sheng-Yong Xu, C.K. Ong // *Chin. Phys.* — 2022. — B. 31(3). — 038701.
6. Xu Jing-Jing. An electromagnetic view of relay time in propagation of neural signals / Jing-Jing Xu, San-Jin Xu, Fan Wang, Sheng-Yong Xu // *Chin. Phys.* — 2021. — B. 30(2). — 028701.
7. Martí Albert. Action potential propagation: ion current or intramembrane electric field? / Albert Martí, Juan J. Pérez, Jordi Madrenas // *Gen. Physiol. Biophys.* — 2018. — V. 37(01). — P. 71 – 82.
8. Zhang Xiqi. Quantum-confined ion superfluid in nerve signal transmission / Xiqi Zhang, Lei Jiang // *Nano Res.* — 2019. — V. 12(6). — P. 1219 – 1221.
9. Song Bo. Cell vibron polariton resonantly self-confined in the myelin sheath of nerve / Bo Song, Yousheng Shu // *Nano Res.* — 2020. — V. 13(1). — P. 38 – 44.
10. Xiang Zuoxian. A primary model of THz and far-infrared signal generation and conduction in neuron systems based on the hypothesis of the ordered phase of water molecules on the neuron surface I: signal characteristics / Zuoxian Xiang, Chuanxiang Tang, Chao Chang, Guozhi Liu // *Sci. Bull.* — 2020. — V. 65(4). — P. 308 – 317.
11. Reutskiy S. Conduction in bundles of demyelinated nerve fibers: computer simulation / S. Reutskiy, E. Rossoni, B. Tirozzi // *Biol. Cybern.* — 2003. — V. 89(6):439-48.
12. Han Kyung-Seok. Ephaptic coupling promotes synchronous firing of cerebellar Purkinje cells / Kyung-Seok Han, Chong Guo, Christopher H. Chen, Laurens Witter, Tomas Osorno, Wade G. Regehr // *Neuron.* — 2018. — V.100(3):564–578.e3..

13. Guo Y.M. Possible mechanism of action potential propagation mediated by static electric field: A novel assumption of understanding nerve interaction and ephaptic coupling / Y.M. Guo, C.K. Ong // *Heliyon*. — 2024. — V. 10. — e37637.
14. Galinsky V.L. The wave nature of the action potential / V.L. Galinsky, L.R. Frank // *Front. Cell. Neurosci.* — 2025. — 19:1467466
15. J. Isakovic, I. Dobbs-Dixon, D. Chaudhury, D. Mitrecic Modeling of inhomogeneous electromagnetic fields in the nervous system: a novel paradigm in understanding cell interactions, disease etiology and therapy / // *Scientific Reports*. — 2018. — 8:12909. — DOI:10.1038/s41598-018-31054-9
16. Anastassiou C.A. Ephaptic coupling of cortical neurons / C.A. Anastassiou, R. Perin, H. Markram, C. Koch // *Nature Neuro Science*. — 2011. — V. 14. — N. 2. — P. 217 – 223.
17. Han Kyung-Seok. Ephaptic Coupling Promotes Synchronous Firing of Cerebellar Purkinje Cells / Kyung-Seok Han, Chong Guo, C.H. Chen, L. Witter, T. Osorno, W.G. Regehr // *Neuron*. — 2018. — V. 100. — P. 564 – 578.
18. Stern S. External Excitation of Neurons Using Electric and Magnetic Fields in One- and Two-dimensional Cultures / S. Stern, A. Rotem, Y. Burnishev, E. Weinreb, E. Moses // *J. Vis. Exp.* — 2017. — V. 123. — e54357.
19. Рамазанова И.Ф., Котов Н.В. Сигнальная система, управляющая конусом роста аксона при воздействии электрическим полем / И.Ф. Рамазанова, Н.В. Котов // *Научно-образовательный журнал для студентов и преподавателей «StudNet»*. — 2021. — №3. — С. 1 – 21.
20. Pinotsis D.A. Cytoelectric coupling: Electric fields sculpt neural activity and “tune” the brain’s infrastructure / D.A. Pinotsis, G. Fridman, E.K. Miller // *Progress in Neurobiology*. — 2023. — V. 226. — 102465.
21. Гришаев А.В. Роль активных и пассивных свойств дендритного дерева нейрона в многоплановой интеграции постсинаптических потенциалов / А.В. Гришаев, В.Ф. Сазонов // *Успехи физиологических наук*. — 2020. — Т. 51. — № 3. — С. 87 – 104.
22. Lorenzo J. A multilayer-multiplexer network processing scheme based on the dendritic integration in a single neuron / J. Lorenzo, S. Binczak, S. Jacquir // *AIMS Neuroscience*. — 2022. — V. 9. — N. 1. — P. 76 – 113.
23. Lorenzo J. Spatiotemporal model of tripartite synapse with perinodal astrocytic process / J. Lorenzo, R. Vuillaume, S. Binczak, S. Jacquir // *Journal of Computational Neuroscience*. — 2020. — V. 48. — P. 1 – 20.
24. Pizá A.G. A Simplified Empirical Modeling of Electrophysiological Activity in a Bundle of Myelinated Nerve Fibers / A.G. Pizá, F.D. Farfán, A.L. Albarracín, F.A. Lucianna, J.H. Soletta, C.J. Felice // *IEEE Latin America Transactions*. — 2016. — V. 14. — N. 7. — P. 3345 – 3350.

25. De Marco N.M. Modeling The Electrical Activity in Myelinated Nerve Fibers: Towards the Electrophysiological Validation of Neuronal Bridges / N.M. De Marco, M.C. Socci, C.B. Goy, A.L. Albarracín, C.J. Felice, F.D. Farfán // Revista Argentina de Bioingeniería. — 2020. — V. 24. — N. 3. — P. 73 – 79.
26. Lucianna F.A. Enhanced Empirical Modeling of Electrophysiological Activity in a Bundle of Myelinated Nerve Fibers: An Open-Source Implementation / N.M. De Marco, M.C. Socci, C.B. Goy, A.L. Albarracín, C.J. Felice, F.D. Farfán // IFMBE Proceedings. — 2024. — V. 114. — P. 432 – 443.
27. Bogatov N.M. Calculation of action potential propagation in nerve fiber / N.M. Bogatov, L.R. Grigoryan, E.G. Ponetaeva, A.S. Sinisyn // Progress in Biophysics and Molecular Biology. — 2014. — V. 114. — P. 170 – 174.
28. 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.
29. Julia G. Mémoire sur l'itération des fonctions rationnelles / G. Julia // Journal de mathématiques pures et appliquées. — 1918. — V. 1. — P. 47 – 245.
30. Fatou P. Sur les substitutions rationnelles / P. Fatou // Comptes Rendus de l'Académie des Sciences de Paris. — 1917. — V. 164. — P. 806 – 808.
31. Mandelbrot B.B. The fractal geometry of nature / B.B. Mandelbrot. — New York: Macmillan, 1983. — 470 pp.
32. Еремин А.Л. Ноогенез и теория интеллекта / А.Л. Еремин. — Краснодар: «Советская Кубань», 2005. — 356 с.
33. Varela F.J. Principles of biological autonomy / F.J. Varela. — MIT Press, 2025. — 408 pp.
34. Богатов Н.М. Фрактальные параметры изменения психофизиологических показателей в результате саморегуляции / Н.М. Богатов, А.Н. Богатова, А.Л. Еремин, С.А. Сухих // Нейроинформатика, её приложения и анализ данных: Материалы XXXIII Всероссийского семинара, 26 сентября 2025 г. Красноярск. — Красноярск: Институт вычислительного моделирования СО РАН, 2025. — С. 3 – 13.

ПРОГНОЗИРОВАНИЕ КОНЦЕНТРАЦИИ УГЛЕКИСЛОГО ГАЗА В АТМОСФЕРЕ ЦЕНТРАЛЬНОЙ СИБИРИ НА ОСНОВЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ВРЕМЕННЫХ РЯДОВ

Н.А.Буряк¹, О.С.Володько²

¹Федеральный исследовательский центр «Красноярский научный центр
Сибирского отделения Российской академии наук», г. Красноярск, Российская
Федерация

buryakna98@gmail.com

²Институт вычислительного моделирования Сибирского отделения Российской
ака-демии наук обособленное подразделение ФИЦ КНЦ СО РАН, г.
Красноярск, Российская Федерация, ***osv@icm.krasn.ru***

Введение. Концентрация углекислого газа CO₂ в атмосфере с 1958 года выросла более чем на 30%. Углекислый газ является основным парниковым газом ответственным за глобальное потепление, таяние ледников, повышение уровня моря, закисление океана и увеличение частоты возникновения экстремальных погодных явлений.

Экосистема Сибири играют ключевую роль в глобальном углеродном цикле, однако её динамика изучена недостаточно из-за удаленности региона и ограниченной сети наземных наблюдений. Научная обсерватории «Станция высотной мачты» (ZOTTO) с 2009 года обеспечивает непрерывные высокоточные измерения концентраций парниковых газов на шести высотах (до 301 м), что позволяет получать репрезентативные данные о фоновом состоянии атмосферы над Сибирью [1].

В мировой практике для прогнозирования CO₂ применяются различные подходы: от классических статистических моделей до современных методов машинного обучения и нейросетевых моделей. Исследование [2] в пригороде Китая продемонстрировало, что случайный лес и градиентный бустинг позволяют строить прогнозы и выделять ключевые метеорологические факторы, влияющие на сезонную динамику CO₂. В работе [3] для прогнозирования применяются нейросетевые модели, в том числе рекуррентная нейронная сеть с архитектурой долгой краткосрочной памяти. В исследовании [4] для прогнозирования

загрязнений воздуха применяется архитектура трансформера временного слияния. Однако, большинство работ либо ориентированы на глобальный масштаб, либо используют данные за короткие периоды. Задача долгосрочного прогнозирования CO_2 с применением нейросетевых архитектур остается недостаточно изученной, особенно для сибирского региона.

Цель настоящей работы – сравнительный анализ эффективности прогноза нейросетевых моделей: долгой краткосрочной памяти и архитектуры трансформера временного слияния, и ансамблевых методов (случайный лес и градиентный бустинг) для прогнозирования ежедневной концентрации CO_2 в атмосфере Центральной Сибири на основе метеорологических параметров.

Материалы и методы. В работе использованы данные ежедневных измерений концентрации CO_2 на станции ZOTTO за период 2009–2022 гг. [5], выполняемые Институтом леса им. В.Н. Сукачева СО РАН (обособленное подразделение ФИЦ КНЦ СО РАН) совместно с Институтом биогеохимии Макса Планка. В качестве параметров для прогноза использованы следующие характеристики: интенсивность пожаров (данные системы управления ресурсами информации о пожарах (FIRMS) [6]), лаговая переменная (количество дней от начала наблюдений), метеорологические параметры: температура воздуха, максимальная и минимальная температура за день, температура точки росы, относительная влажность, скорость ветра, атмосферное давление, количество осадков (данные с сайта Национального управления по авиации и исследованию космического пространства (NASA) [7]).

Для сравнительного анализа были реализованы ансамблевые модели машинного обучения: случайный лес [8], градиентный бустинг [9], нейросетевая модель долгой краткосрочной памяти [10], архитектура трансформера временного слияния [4].

Оценка качества проводилась по метрикам: средняя квадратичная ошибка (MSE), средняя абсолютная ошибка (MAE), коэффициент детерминации (R^2).

Результаты. Для оценки качества работы моделей выборка была разделена на обучающую (60%), валидационную (15%) и тестовую (25%) части с сохранением хронологического порядка. Все модели обучались на обучающей

выборке, и проверялись на валидационной, результаты работы моделей на данных NASA представлены в Таблице 1.

Таблица 1

Сравнение качества прогноза ансамблевых моделей и нейросетевых архитектур

Модель	<i>MAE</i>	<i>RMSE</i>	R^2
Случайный лес	5,23	7,06	0,42
Градиентный бустинг	4,74	6,23	0,55
LSTM	2,87	3,91	0,83
TFT	2,29	3,50	0,90

Как видно из таблицы, нейросетевые архитектуры значительно превосходят ансамблевые методы. Преимущество нейросетевых моделей объясняется их способностью учитывать временную структуру данных через механизм вентилях (LSTM) и механизм внимания (TFT), тогда как ансамблевые методы оперируют фиксированным набором признаков без учёта последовательности.




Рис. 1. Прогноз CO₂ на основе архитектуры трансформера временного слияния
 $MAE = 2,72$, $RMSE = 3,84$, $R^2 = 0,86$

Для оценки обобщающей способности в условиях, максимально приближенных к реальному применению был проведен дополнительный этап тестирования. Модель трансформера временного слияния была обучена на данных за 2009–2018 гг., после чего её веса были сохранены и применены к независимому периоду 2019–2022 гг. без дообучения (Рисунок 1).

Также был проведен анализ важности признаков при помощи построения матрицы корреляций, применения метода перестановок на основе алгоритма случайного леса, а также оценка вклада признаков вследствие применения метода главных компонент. Анализ показал, что наибольший вклад в прогноз вносят температура воздуха, скорость ветра, относительная влажность и длинноволновая входящая радиация.

Далее была проверена прогностическая способность самих метеорологических параметров. Для каждого из четырёх отобранных признаков была обучена модель TFT на исторических данных 2009–2018 гг., после чего выполнялся прогноз на период 2019–2022 гг. Верификация показала высокую точность прогнозирования каждого из параметров на трёхлетнем горизонте.

Таблица 2

Оценка точности прогноза метеопараметров

Метеопараметр	<i>MAE</i>	<i>RMSE</i>	<i>R</i>²
ДВ входящая радиация	11,11	14,35	0,96
Минимальная температура	1,93	2,81	0,967
Относительная влажность	2,12	3,71	0,794
Скорость ветра	0,16	0,24	0,613.

Таким образом, установлено, что выбранные предикторы обладают хорошей предсказуемостью, что позволяет их использовать в каскадной схеме долгосрочного прогноза.

На основе обученных нейросетевых моделей и каскадной схемы был выполнен прогноз концентрации CO₂ на период с 2026 по 2029 год. Для этого сначала с помощью отдельной нейросетевой модели, обученной на исторических метеоданных (2009–2025 гг.), были спрогнозированы значения четырёх ключевых метеорологических параметров на три года вперёд. Полученные прогнозные метеоданные затем подавались на вход обученной модели CO₂. Веса модели CO₂ при этом не изменялись.

На рисунке 2 представлен полученный прогноз среднесуточной концентрации CO₂ на 2026–2029 гг. Видно, что прогнозируемый ряд

демонстрирует продолжение тренда роста концентрации CO_2 , что согласуется с глобальными наблюдениями (ежегодный прирост $\sim 2.3\text{--}2.5$ ppm) и подтверждает устойчивость выявленных закономерностей. Сезонная динамика (минимум летом, максимум зимой) также сохраняется, что указывает на достоверность каскадного подхода.




Рис. 2. Прогноз уровня CO_2 на 2026–2029 гг.

Заключение. Проведен сравнительный анализ ансамблевых методов и нейросетевых для прогнозирования ежедневной концентрации углекислого газа в Центральной Сибири. Показано, что архитектура трансформера временного слияния превосходит ансамблевые методы (случайный лес и градиентный бустинг) и нейросетевую модель долгой краткосрочной памяти по точности прогноза.

Установлено, что ключевыми метеорологическими предикторами для прогноза углекислого газа являются температура воздуха, относительная влажность, скорость ветра и длинноволновая входящая радиация. Выявленная высокая значимость температуры и влажности как предикторов согласуется с физикой процесса: температура воздуха контролирует интенсивность дыхания экосистем, влажность – активность фотосинтеза, скорость ветра отвечает за рассеивание частиц в воздухе, а длинноволновая входящая радиация – главный фактор, определяющий фотосинтез, так как чем больше солнечного, тем активнее растения поглощают CO_2 .

Каскадный подход, включающий отдельное прогнозирование метеопараметров с последующим применением обученной модели CO_2 , показал свою работоспособность и позволяет получать долгосрочные прогнозы (до 3–5

лет) на основе открытых метеорологических данных. Полученный прогноз на 2026–2029 гг. демонстрирует продолжение тренда роста концентрации CO₂ в атмосфере над Центральной Сибирью, что согласуется с глобальными наблюдениями и подтверждает устойчивость выявленных закономерностей.

Список литературы

1. Timokhina A. V., Prokushkin A. S., Panov A. V., Kolosov R. A., Sidenko N. V., Lavric J., Heimann M. Interannual variability of atmospheric CO₂ concentrations over central Siberia from ZOTTO data for 2009–2015 // *Russian Meteorology and Hydrology*. – 2018. – Vol. 43, No. 5. – P. 288–294. – DOI: 10.3103/S1068373918050023.
2. Liu W., Niu Z., Feng X., Zhou W., Liang D., Wang G., Liu L. Determining the Key Meteorological Factors Affecting Atmospheric CO₂ and CH₄ Using Machine Learning Algorithms at a Suburban Site in China // *Urban Climate*. – 2025. – Vol. 59. – P. 102312. – DOI: 10.1016/j.uclim.2025.102312.
3. Rezaei Z., Samghabadi S. S., Amini M. A., Shi D., Banad Y. M. Predicting Climate Change: A Comparative Analysis of Time Series Models for CO₂ Concentrations and Temperature Anomalies // *Environmental Modelling & Software*. – 2025. – Vol. 192. – P. 106533. – DOI: 10.1016/j.envsoft.2025.106533.
4. Rath S., Maneesha P. Air pollution forecasting using machine learning with Temporal Fusion Transformer and Graph Neural Networks // 2025 3rd International Conference on Intelligent Data Communication Technologies and Internet of Things (ICIDC IoT). – Bengaluru, India, 2025. – P. 1798–1803.
5. Dieu Anh T., Gerbig C., Rödenbeck C., Panov A., Prokushkin A., Winderlich J., Lavrič J., Heimann M., Seifert T., Schultz U., Schmidt S., Zaehle S. Zotino Tall Tower Observatory (ZOTTO) Hourly CO₂ Measurement Dataset [Электронный ресурс] // Edmond. – 2024. – Режим доступа: <https://doi.org/doi:10.17617/3.YBPFG2> (дата обращения: 10.02.2026).

6. NASA FIRMS: Fire Information for Resource Management System [Электронный ресурс]. – Режим доступа: <https://firms.modaps.eosdis.nasa.gov/> (дата обращения: 10.02.2026).
7. NASA POWER: Prediction Of Worldwide Energy Resources [Электронный ресурс]. – Режим доступа: <https://power.larc.nasa.gov/> (дата обращения: 10.02.2026).
8. Biau G., Scornet E. A Random Forest Guided Tour // Test. – 2016. – Vol. 25, No. 2. – P. 197–227. – DOI: 10.1007/s11749-016-0481-7.
9. Xie Y., Tummala S. P. Machine Learning for Sensor Analytics: A Comprehensive Review and Benchmark of Boosting Algorithms in Healthcare, Environmental, and Energy Applications // Sensors. – 2025. – Vol. 25, No. 23. – P. 7294. – DOI: 10.3390/s25237294.
10. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. – 1997. – Vol. 9, No. 8. – P. 1735–1780.

DISTILLING TEXTURE LOSSES THROUGH PROJECTED DESCENT DIRECTIONS

M.V. Gorshkov¹, Z.M. Shibzukhov^{1,2}

¹Moscow Pedagogical State University (MPGU), Moscow, Russia

²Institute for Theoretical and Applied Electromagnetics of RAS, Moscow, Russia

mvgorshkofff@gmail.com; szport@gmail.com

Introduction

Classical neural texture synthesis formulates image generation as the optimization of a randomly initialized pixel array. During optimization, feature statistics of the synthesized image are matched to the statistics of a target texture computed by a pre-trained convolutional network [1, 2]. This formulation does not require training a separate model for each texture and can be used with different optimizers. However, it relies on a long iterative process in which every step includes forward and backward passes through a large network. As a result, producing a high-quality image usually takes substantial time.

Common ways to accelerate synthesis include training feed-forward image transformations [4, 5], approximating a perceptual metric [6], or predicting its gradient directly [7]. In this work we keep the original optimization-based formulation but replace the objective being optimized. A fixed VGG-based loss acts as the teacher, while a trainable loss with a VGG-like feature extractor acts as the student. The learned object is still a differentiable loss function and can therefore be used with standard optimizers such as SGD, Adam, and LBFGS.

The student is not trained to reproduce the teacher values or its local gradients. Instead, it learns to form a more useful field of descent directions. To do this, we use stored teacher optimization trajectories: the direction proposed by the student at the current point is projected to the scale of the remaining displacement toward the end of the trajectory and is then evaluated by the teacher. Thus, the object of distillation is the geometry of descent. Experiments on DTD and Places365 show lower target metrics after a fixed optimization budget in most tested regimes. A normalized-gradient control indicates that the gain is explained not only by the step magnitude but also by the quality

of the learned descent direction.

Method

Overview. The goal is to distill a fixed teacher loss into a trainable student loss so that the student gradients define more efficient synthesis trajectories. Training uses only the projection loss: the student does not reproduce teacher values, gradients, or intermediate states. The teacher trajectory provides the current state x_{start} and the final state x_{final} , the student proposes a local direction, and the teacher evaluates the result of extending this direction.

Teacher and student losses. Let x^* be a real target texture. The fixed teacher feature extractor is denoted by φ_T , and the trainable student extractor with parameters θ is denoted by φ_S . At each selected VGG layer, the feature map is represented by channel-wise means and standard deviations; statistics from all layers are concatenated into a single vector [3].

$$\varphi_{T/S}(x) = \text{concat}_l[\mu_l(x), \sigma_l(x)]. \quad (1)$$

The corresponding losses have the same form, but the teacher parameters are fixed while the student parameters are trainable:

$$L_T(x, x^*) = \|\varphi_T(x) - \varphi_T(x^*)\|_2^2, L_S(x, x^*; \theta) = \|\varphi_S(x; \theta) - \varphi_S(x^*; \theta)\|_2^2. \quad (2)$$

Teacher trajectories. For each target texture, teacher optimization starts from noise and produces the stored sequence of states

$$x_0, x_1, \dots, x_T. \quad (3)$$

The initial image x_0 is noise, while x_T is the final teacher result. During training, the endpoint is always used as x_{final} , while the projection is evaluated against the target texture x^* .

Continuous position sampling. Uniform sampling by optimizer step over-weights late small refinements. Therefore, for each step we compute its length d_t and the normalized accumulated path coordinate p_t :

$$d_t = \|x_{t+1} - x_t\|_2, p_t = \frac{\sum_{i < t} d_i}{\sum_{i < T} d_i}. \quad (4)$$

At each epoch, $u \in [0,1]$ is sampled, an interval $p_t \leq u \leq p_{t+1}$ is found, and x_{start} is obtained by linear interpolation between neighboring states. This gives a continuous set of starting points and distributes visible texture changes more evenly.




Fig. 1. States sampled uniformly by optimizer time (top row) and by path length (bottom row).

One student step. At the selected state, one gradient step is taken with respect to the student loss:

$$x_{\text{next}} = x_{\text{start}} - \nabla_x L_S(x_{\text{start}}, x^*; \theta). \quad (5)$$

The update induced by the student is denoted by u_s :

$$u_s = x_{\text{next}} - x_{\text{start}} = -\nabla_x L_S(x_{\text{start}}, x^*; \theta). \quad (6)$$

The absolute scale of the local step is not used directly: the direction is preserved and then transferred to the scale of the remaining teacher displacement.

Projection to the endpoint scale. The remaining displacement from the current state to the teacher result is

$$r_T = x_{\text{final}} - x_{\text{start}}. \quad (7)$$

The student update is rescaled to the same norm:

$$u_s = \frac{\|r_T\|_2}{\|u_s\|_2 + \epsilon} u_s. \quad (8)$$

The projected image is then constructed as

$$x_{\text{proj}} = x_{\text{start}} + u_s. \quad (9)$$

The quantity x_{proj} answers the question: where would the local student direction lead if it were extended to the full remaining scale of the teacher trajectory?

Projection loss. The projected image is evaluated in the fixed teacher feature space against the real target texture:

$$L_{\text{proj}}(\theta) = \|\varphi_T(x_{\text{proj}}) - \varphi_T(x^*)\|_2^2. \quad (10)$$

This is the only training loss. The student is not required to reproduce the trajectory step by step: its local direction should, after large extrapolation, reach a region that the teacher considers stylistically close to the target. The method can therefore be interpreted as distilling a useful gradient field rather than a particular optimizer. Training requires differentiating through the student gradient; for stability, max-pooling in the trainable extractor is replaced with average-pooling, while the fixed teacher is left unchanged.

Experimental setup

Training was performed on the Describable Textures Dataset (DTD) [9]. We used 2000 textures to build training trajectories and 200 images as a fixed validation subset. Trajectories were generated at resolution 64×64 pixels by the fixed VGG16 teacher using layers [1,3,6]: 200 Adam steps with learning rate 0.03. At each epoch, 30 random path positions were sampled for each image; the student was trained for 10 epochs with batch size 16 and Adam learning rate 0.001.

Evaluation was performed on 100 held-out DTD images and 100 randomly selected images from the Places365 validation set [10]. The latter set served as an external sample of scene images containing pronounced texture structures. For every setting, the teacher and the student started from the same noise. We measured the distance in the teacher style space (Style) and the multiscale Gaussian-pyramid loss (GPSL); for both metrics, lower values indicate a better match to the target.

The GPSL metric sums discrepancies between style statistics at several levels of a Gaussian pyramid:

$$L_{\text{GPSL}}(x, x^*) = \sum_{s=0}^S \lambda_s \|\psi(G_s(x)) - \psi(G_s(x^*))\|_2^2. \quad (11)$$

Here $G_s(\cdot)$ denotes a Gaussian-pyramid level, ψ is the vector of channel-wise feature means and standard deviations, and λ_s is a fixed level weight. Therefore, GPSL evaluates texture matching not only at the original scale but also after successive smoothing and downsampling.

Results

In the practical sweep, we used SGD with learning rates $\{3; 10; 30\}$, Adam with learning rates $\{0.003; 0.01; 0.03\}$, and LBFGS with learning rates $\{0.1; 0.3; 1.0\}$. Under sufficiently active optimization, the student usually outperformed the teacher on both metrics. For example, with Adam at learning rate 0.03, GPSL on DTD decreased from 0.8993 to 0.4679, and on Places365 from 1.0947 to 0.5687. With LBFGS at learning rate 0.3, the corresponding values were 0.5898 versus 0.3439 and 0.7055 versus 0.4681. With overly small steps, the advantage was not always visible.

To separate direction quality from gradient scale, we ran a control experiment in which teacher and student gradients were normalized before each of 100 steps. The table reports teacher/student pairs. The student is better in 14 out of 16 comparisons, including all GPSL values.

Normalized-gradient control: teacher/student values

Step norm	DTD Style	DTD GPSL	Places365 Style	Places365 GPSL
0.5	0.0236 / 0.0159	1.0036 / 0.5493	0.0167 / 0.0183	1.1989 / 0.6560
1.0	0.0226 / 0.0117	0.9063 / 0.4600	0.0174 / 0.0125	1.1019 / 0.5656
2.0	0.0312 / 0.0170	0.9253 / 0.4677	0.0258 / 0.0144	1.1283 / 0.5565
4.0	0.0654 / 0.0460	1.0658 / 0.5898	0.0461 / 0.0280	1.1815 / 0.5937




Fig. 2. Example teacher trajectories (top row) and student trajectories (bottom row) with step norm 2.0.

The persistence of the advantage at equal step length means that the result cannot be explained only by a larger student gradient norm. Projected training changes the

direction field itself: already at intermediate iterations it forms a more pronounced structure of the target texture. At the same time, the method is not tied to a single inference optimizer, because it learns a scalar loss rather than a specific update rule [8].

Limitations and conclusion

The experiments are limited to 64×64 resolution, a VGG16 representation, and relatively small subsets. We did not measure subjective quality or total wall-clock time including the preliminary construction of trajectories. Training also requires second-order derivatives, so the gain is most relevant when the learned student loss is reused many times afterwards.

The proposed approach shows that a fixed perceptual loss can be distilled not by copying its local gradient, but by evaluating projected directions. The resulting student loss remains compatible with standard optimizers and reaches images with lower Style and GPSL errors after the same optimization budget in most tested regimes. The normalized-gradient control indicates that the key effect is associated with a more useful geometry of descent directions.

Список литературы

1. Gatys L.A. Texture synthesis using convolutional neural networks / L.A. Gatys, A.S. Ecker, M. Bethge // *Advances in Neural Information Processing Systems*. – 2015. – Vol. 28.
2. Gatys L.A. Image style transfer using convolutional neural networks / L.A. Gatys, A.S. Ecker, M. Bethge // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. – 2016. – P. 2414–2423.
3. Li Y. Demystifying neural style transfer / Y. Li, N. Wang, J. Liu, X. Hou // *Proceedings of the 26th International Joint Conference on Artificial Intelligence*. – 2017. – P. 2230–2236.
4. Johnson J. Perceptual losses for real-time style transfer and super-resolution / J. Johnson, A. Alahi, L. Fei-Fei // *European Conference on Computer Vision*. – Springer, 2016. – P. 694–711.

5. Ulyanov D. Texture networks: Feed-forward synthesis of textures and stylized images / D. Ulyanov, V. Lebedev, A. Vedaldi, V. Lempitsky // Proceedings of the 33rd International Conference on Machine Learning. – 2016. – P. 1349–1357.
6. Zhang R. The unreasonable effectiveness of deep features as a perceptual metric / R. Zhang, P. Isola, A.A. Efros, E. Shechtman, O. Wang // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2018. – P. 586–595.
7. Nikulin A. Perceptual gradient networks / A. Nikulin, R. Suvorov, A. Ivakhnenko, V. Lempitsky. – E-print: <https://arxiv.org/abs/2107.07165> (accessed: 29.06.2026).
8. Andrychowicz M. Learning to learn by gradient descent by gradient descent / M. Andrychowicz, M. Denil, S. Gomez et al. // Advances in Neural Information Processing Systems. – 2016. – Vol. 29.
9. Cimpoi M. Describing textures in the wild / M. Cimpoi, S. Maji, I. Kokkinos, S. Mohamed, A. Vedaldi // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. – 2014. – P. 3606–3613.
10. Zhou B. Places: A 10 million image database for scene recognition / B. Zhou, A. Lapedriza, A. Khosla, A. Oliva, A. Torralba // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2018. – Vol. 40. – No. 6. – P. 1452–1464.

ВОССТАНОВЛЕНИЕ ПАРАМЕТРОВ ТАКТИЛЬНОГО КОНТАКТА ПО ДАНЫМ МАГНИТНОГО СЕНСОРА: ОТ ПОПИКСЕЛЬНОЙ КЛАССИФИКАЦИИ К ФИЗИЧЕСКИ-ИНФОРМИРОВАННОЙ ПАРАМЕТРИЗАЦИИ

М.Г. Доррер¹, Т.А. Шалыгина², А.И. Дудник²

¹ Сибирский государственный университет науки и технологий им. М.Ф. Решет-
нева, Россия, г. Красноярск, пр. Мира, д.82, mdorrer@mail.ru

² Общество с ограниченной ответственностью «ИнтеллектСистемы», Россия, г.
Красноярск, ул. Академика Вавилова, д. 11, оф. 2-18

Аннотация

Рассмотрена задача восстановления пространственных параметров контакта по показаниям магнитного тактильного сенсора, состоящего из девяти датчиков Холла (3×3) и магнитной мембраны NdFeB/PDMS. Стандартный подход – попиксельная бинарная классификация карты контакта 25×25 – демонстрирует низкое качество (IoU 0,16) из-за сильного дисбаланса классов и несоразмерности размерностей входного (27 признаков) и выходного (625 пикселей) пространств. Предложен переход к параметрическому представлению контакта: эллиптическая форма с адаптивным переходом к кругу при малых площадях, дополненная soft-argmax-головой для субпиксельной локализации центра. Показано, что такая физически-информированная архитектура повышает IoU до 0,244 при сокращении числа выходных параметров со 625 до 5. Анализ ошибок по диапазонам силы выявляет фундаментальный предел локализации при малых деформациях.

Ключевые слова: магнитный тактильный сенсор, датчики Холла, soft-argmax, параметрическая растеризация, дифференцируемый рендеринг, физически-информированные нейронные сети

Введение

Магнитные тактильные сенсоры занимают важное место в робототехнике благодаря компактности, герметичности и совместимости с методами медицинской визуализации. Типичная конструкция включает магнитную мембрану (NdFeB/PDMS), деформирующуюся под действием нагрузки, и матрицу датчиков

Холла, регистрирующих изменение магнитного поля (рис. 1). Обратная задача – восстановление пространственного распределения контакта по показаниям датчиков – является недоопределённой и существенно нелинейной.




Рис. 1. Концептуальная схема магнитного тактильного сенсора.

Ранее в работе [1] была предложена конструкция сенсора с 3×3 матрицей датчиков Холла, обеспечивающая разрешение локализации порядка 1,2 мм при использовании CNN для обработки сигналов. Аналогичные подходы демонстрируют возможность достижения сверхразрешения: в работе [2] описана магнитная кожа с точностью локализации 1,2 мм при использовании всего 4×4 тактилей.

Постановка задачи. Данные представлены в двух режимах. В режиме точечного индентора каждая временная последовательность соответствует нажатию в одной точке, и требуется восстановить карту давления (25×25), глубину и диаметр. В режиме распределённого (многоточечного) индентора требуется восстановить бинарную карту контакта 25×25 и общую силу. Входной сигнал в обоих случаях – 27 чисел ($9 \text{ датчиков} \times 3 \text{ компоненты } V_x, V_y, V_z$). Соотношение размерностей входа и выхода (27 против 625) иллюстрирует фундаментальную несоразмерность задачи (рис. 2).




Рис. 2. Сравнение двух парадигм: попиксельная классификация vs параметрическое представление.

Связанные работы. Машинное обучение для тактильного восприятия активно развивается. Обзор [3] систематизирует методы обработки тактильных сигналов, включая CNN, LSTM и гибридные архитектуры. В работе [4] предложен гибридный подход для восстановления карты сил ERT-сенсора, сочетающий симуляцию и реальные данные. Работа [5] демонстрирует применение нейронных полей контакта для отслеживания внешнего контакта. Методы суперразрешения для тактильных сенсоров рассмотрены в [6], где CNN используются для повышения пространственного разрешения магнитной кожи.

Физически-информированные нейронные сети (PINN) активно применяются в контактной механике [7]: PINN решают прямые и обратные задачи малых упругих деформаций с контактными ограничениями. Дифференцируемый рендеринг для тактильных сенсоров развивается в работах [8, 9], где физически-корректная симуляция используется для генерации обучающих данных и оптимизации параметров сенсора.

Однако большинство работ фокусируются на оптических тактильных сенсорах (GelSight, DIGIT), тогда как магнитные сенсоры с матрицей Холла изучены меньше. Кроме того, стандартный подход – попиксельная классификация – не учитывает физическую структуру контакта: при сферическом инденторе область контакта односвязна и близка к эллипсу.

Цель работы – разработать физически-информированную нейросетевую архитектуру для восстановления параметров контакта по данным магнитного сенсора, преодолевающую ограничения по픽сельной классификации.

Постановка задачи и экспериментальные материалы

Экспериментальная установка и данные

Сенсор состоит из печатной платы с матрицей 3×3 датчиков Холла (шаг 6 мм), буферного слоя PDMS и магнитной мембраны NdFeB/PDMS. Индентор (сфера диаметром 3 или 6 мм) последовательно нажимает на все точки рабочей области (круг диаметром 24 мм, шаг 1 мм). В каждой точке индентор опускается с шагом 0,1 мм до достижения целевой силы (200–600 г).

Запись содержит для каждого кадра: время, координату Coor (закодированный индекс точки), силу Fz, показания 27 датчиков Холла и бинарную маску контакта (625 значений C_i). Объём: 75 742 кадра, 3 517 нажатий.

Предобработка данных

Применялись следующие методы предобработки: скользящее среднее (окно 5 кадров) для подавления шума; аугментация масштабированием ($\alpha \in [0,05; 0,5]$) для увеличения представленности малых сил; взвешенная бинарная кросс-энтропия с весом положительного класса $POS_WEIGHT = 20$ для компенсации дисбаланса; гауссово размытие целевых карт ($\sigma = 1,0$) для сглаживания градиентов. Разделение данных выполнялось по экспериментам (ExpID) в пропорции 80/10/10.

Параметрическое представление контакта

Вместо 625 бинарных выходов введено 5 параметров: центр (x_0, y_0) , логарифм площади $\log A$, вытянутость $\rho = \log(a/b)$ и угол наклона φ . Параметры извлекаются из моментов истинной маски: $A = \sum m_i$, $x_0 = \frac{1}{A} \sum x_i m_i$, $y_0 = \frac{1}{A} \sum y_i m_i$

Центральные моменты второго порядка дают ρ и φ . Для масок с $A < 5$ параметры ρ и φ обнуляются как нестабильные.




Рис. 3. Извлечение параметров из бинарной маски контакта.

Дифференцируемая растеризация

Кастомный слой EllipseCircleRasterizer строит мягкую маску:

$$m_{\sim}(x, y) = \sigma(\kappa \cdot [w(A) \cdot d_{\text{ell}} + (1 - w(A)) \cdot d_{\text{circ}}])$$

где $w(A) = \sigma((A - A_0)/\tau)$ – вес перехода, d_{ell} и d_{circ} – расстояния до границ эллипса и круга. Параметры: $A_0 = 5$, $\tau = 2$, $\kappa = 10$.




Рис. 4. Адаптивное смешивание круга и эллипса в зависимости от площади.

Soft-argmax для локализации центра

Голова Dense(625) с softmax предсказывает распределение вероятностей по пикселям. Координаты центра вычисляются как взвешенное среднее:

$$\hat{x}_0 = \sum p_i x_i, \hat{y}_0 = \sum p_i y_i$$

Обучение – категориальная кросс-энтропия на one-hot пикселе, ближайшем к истинному центру. Это обеспечивает субпиксельную точность и даёт бесплатную оценку неопределённости через энтропию распределения.




Рис. 5. Архитектура soft-argmax-головы и интерпретация распределения.

Архитектуры моделей.

Рассматривались три архитектуры: свёрточная (conv_small – два Conv2D-слоя на входе $3 \times 3 \times 3$), свёрточная с транспонированием (conv_transpose_small) и полносвязная (mlp_2_256_128). Функции потерь: Dice для маски, cross-entropy для центра, MAE для $\log A$, MSE для ρ и φ , MSE для силы. Веса: $W_{center} = 2,0$, $W_{\log A} = 1,0$, $W_{shape} = 0,5$, $W_{force} = 0,3$.

Результаты

Сравнение постановок

Попиксельная бинарная классификация (625 независимых сигмоид) дала ассурасу 98%, но IoU 0,16 – классический симптом дисбаланса классов. Параметризация с прямой регрессией центра повысила IoU до 0,199. Добавление soft-argmax дало финальный результат IoU = 0,2445, что на 22,9% выше попиксельного подхода.

Сравнение архитектур

Табл. 1. Параметры предсказательной способности моделей.

Модель	Параметры	IoU	F1	MAE_{x_0}	MAE_{y_0}	$MAE_{\log A}$
conv_small	61 861	0,2445	0,3289	2,342	2,629	0,5658

conv_transpose_small	60 109	0,2339	0,3181	2,376	2,662	0,5830
mlp_2_256_128	122 741	0,2134	0,2898	2,466	2,839	0,5641

Свёрточная архитектура conv_small выиграла с минимальным числом параметров. Полносвязная модель с в 2 раза большим числом параметров показала худший IoU – пространственная структура датчиков $3 \times 3 \times 3$ плохо обрабатывается MLP.

Зависимость качества от силы

Табл. 2. Зависимость предсказательной способности от силы

Диапазон, г	IoU	MAE_x ₀	MAE_y ₀	N
0–50	0,0529	4,35	4,98	4061
50–100	0,2287	2,13	2,44	2164
100–150	0,2956	1,51	1,71	1837
200–250	0,3544	1,14	1,24	1016
400–600	0,4628	1,01	0,96	783

Корреляция силы и IoU: $r = 0,50$ ($p < 0,001$). При малых силах (0–50 г, 44% данных) IoU катастрофически низок (0,05), при больших – достигает 0,46. MAE центра падает с 4,35 до 1,01 пикселя. Зависимость визуализирована на рис. 6.




Рис. 6. Зависимость IoU от силы, приложенной к индентору.

Анализ неопределённости

Энтропия распределения центра сильно коррелирует с ошибкой локализации: $r = 0,82$ ($p < 0,001$). Это означает, что модель «знает», когда она не уверена. Медиана ошибки центра 1,91 пикселя, но 90-й перцентиль достигает 10,23 – тяжёлый хвост сосредоточен в области малых сил (рис. 7).




Рис. 7. Энтропия предсказаний по диапазонам силы.

Обсуждение

Физический предел локализации

Полученные результаты указывают на фундаментальное ограничение: при малых силах (< 50 г) деформация мембраны минимальна, изменение магнитного поля сопоставимо с шумом датчиков, и 27 чисел не содержат достаточной информации для точной локализации. Это не проблема архитектуры, а физический предел сенсора. Корреляция силы и ошибки центра ($r = -0,47$) подтверждает этот вывод (рис. 7).

Преимущества параметризации

Переход от 625 пикселей к 5 параметрам даёт тройной выигрыш: (1) резкое снижение размерности выхода и переобучения; (2) физическая интерпретируемость – каждое число имеет смысл; (3) устойчивость на малых пятнах за счёт адаптивного перехода к кругу. Параметризация сглаживает градиенты и позволяет модели работать с ограниченными данными.

Soft-argmax как источник неопределённости

Сильная корреляция энтропии и ошибки ($r = 0,82$) открывает практические возможности: отбраковка неуверенных предсказаний, адаптивная температура softmax, активное обучение. Это делает модель «self-aware» – она знает границы своей применимости.

Ограничения

Работа ограничена сферическими инденторами. Для инденторов сложной формы (многоточечных, асимметричных) эллиптическая параметризация может оказаться недостаточной. Кроме того, все эксперименты проведены в лабораторных условиях без внешних магнитных помех.

Вывод

Предложена физически-информированная нейросетевая архитектура для

восстановления параметров тактильного контакта по данным магнитного сенсора. Ключевые вклады: (1) параметрическое представление контакта (5 параметров вместо 625 пикселей); (2) дифференцируемая растеризация с адаптивным переходом «эллипс–круг»; (3) soft-argmax для субпиксельной локализации центра с бесплатной оценкой неопределённости. Итоговый IoU = 0,2445 при 61 861 параметре — лучший результат среди всех рассмотренных архитектур.

Дальнейшие направления: временные модели (LSTM/GRU) для накопления сигнала при малых силах; двухстадийная схема (грубая классификация зоны + уточнение); расширение сенсора для работы с распределёнными контактами.

Благодарность

Исследование выполнено при финансовой поддержке гранта Фонда содействия инновациям (Старт-ИИ-1-2025 (очередь 1)) договор № 23ГС1ИИОРС22/111780.

Список литературы

1. Zhao P., Hu H., Zhang C. et al. Large-area Magnetic Skin for Multi-point and Multi-scale Tactile Sensing with Super-resolution // npj Flexible Electronics. 2024. Vol. 8, No. 1. DOI: 10.1038/s41528-024-00325-z
2. J. Huang, Y. Lou, X. Xiong, X. Yang, and Y. Li, Multipole Magnetic Tactile Sensor With Super-Resolution for 3-D Pose Estimation // IEEE Transactions on Instrumentation and Measurement. 2024. Article 9501911. DOI: 10.1109/TIM.2024.3522631
3. Hu Z., Lin L., Lin W. et al. Machine Learning for Tactile Perception: Advancements, Challenges, and Opportunities // Advanced Intelligent Systems. 2023. Vol. 5, No. 7. DOI: 10.1002/aisy.202200371
4. Lee H., Sun H., Park H. et al. Predicting the Force Map of an ERT-Based Tactile Sensor Using Simulation and Deep Networks // IEEE Transactions on Automation Science and Engineering. 2023. Vol. 20, No. 1. P. 425–439. DOI: 10.1109/TASE.2022.3156184
5. Higuera C., Dong S., Boots B., Mukadam M. Neural Contact Fields: Tracking Extrinsic Contact with Tactile Sensing // arXiv preprint arXiv:2210.09297v1
6. Zhou, Y., Luo, Y., Yan, Z., Jin, Y., Jiang, S., Wang, Z., et al. Simulation, Design, and Application of Intelligent-Edge-Based Soft Magnetic Tactile Sensor With

- Super-Resolution // IEEE Sensors Journal. 2024. DOI: 10.1109/JSEN.2024.3486921
7. Sahin T., von Danwitz M., Popp A. Solving Forward and Inverse Problems of Contact Mechanics using Physics-Informed Neural Networks // arXiv preprint arXiv:2308.12716. 2023. DOI: 10.1186/s40323-024-00265-3
 8. Z. Chen, S. Zhang, S. Luo, F. Sun, and B. Fang, Tacchi: A pluggable and low computational cost elastomer deformation simulator for optical tactile sensors, IEEE Robotics and Automation Letters, vol. 8, no. 3, pp. 1239–1246, 2023 // DOI: 10.1109/LRA.2023.3237042
 9. Funk, N. High-Resolution Pixelwise Contact Area and Normal Force Estimation for the GelSight Mini Visuotactile Sensor Using Neural Networks / N. Funk, P. O. Müller, B. Belousov, A. Savchenko, R. Findeisen, J. Peters // Embracing Contacts — Workshop at ICRA 2023. — 2023. — URL: <https://openreview.net/forum?id=dUO0QQw4FW>
 10. Hu X., Venkatesh A., Wan Y. et al. Learning to Detect Slip through Tactile Estimation of the Contact Force Field and its Entropy Properties // Mechatronics. 2024. DOI: 10.1016/j.mechatronics.2024.103258
 11. Bauza M., Bronars A., Rodriguez A. Tac2Pose: Tactile Object Pose Estimation from the First Touch // International Journal of Robotics Research. 2023. Vol. 42, No. 13. DOI: 10.1177/02783649231196925
 12. C. Du, F. Bernabei, M. L. Preti and L. Beccai, "Design and Optimization of a Soft Magnetic Tactile Sensor," 2023 IEEE SENSORS, Vienna, Austria, 2023, pp. 1-4, DOI: 10.1109/SENSORS56945.2023.10325164.
 13. Lim, B. High-Load Capable Soft Tactile Sensors: Incorporating Magnetorheological Elastomer for Accurate Contact Detection and Classification of Asymmetric Mechanical Components / B. Lim, J. Yoon // Advanced Intelligent Systems. — 2024. — Vol. 7. — DOI: 10.1002/aisy.202400275.
 14. Mêda, F. Skin-Inspired Magnetoresistive Tactile Sensor for Force Characterization in Distributed Areas / F. Mêda, F. Näf, T. P. Fernandes [et al.] // Sensors. — 2025. — Vol. 25, № 12. — Art. 3724. — DOI: 10.3390/s25123724.
 15. Worth, A. J. A neural network for tactile sensing: the Hertzian contact problem / A. J. Worth, R. R. Spencer // IEEE Transactions on Systems, Man, and Cybernetics. — 1992. — Vol. 22, no. 1. — P. 177–182. — DOI: 10.1109/21.141323.

ИССЛЕДОВАТЕЛЬСКИЙ АНАЛИЗ ДАННЫХ ДОЛГОСРОЧНОГО МОНИТОРИНГА ПРИЗЕМНОГО СЛОЯ АТМОСФЕРЫ В КРАСНОЯРСКОЙ ПРОМЫШЛЕННОЙ АГЛОМЕРАЦИИ¹

Е.Д.Карепова¹, А.В. Филиппов¹, Ю.В.Шанько¹

¹Институт вычислительного моделирования СО РАН, *e.d.karepova@icm.krasn.ru, shy70@mail.ru*

Федеральный проект «Чистый воздух» является одним из ключевых инструментов государственной экологической политики, направленной на снижение выбросов загрязняющих веществ в атмосферу промышленных городов России. Красноярск входит в число городов-участников проекта с 2019 года и остаётся одной из наиболее значимых территорий для оценки эффективности реализуемых природоохранных мер. Для города установлены конкретные целевые ориентиры по снижению выбросов, однако экологическая обстановка, особенно в зимний отопительный период, по-прежнему остаётся неблагоприятной. Так, в феврале 2026 года Красноярск дважды — 5 и 25 февраля — входил в десятку наиболее загрязнённых крупных городов мира по версии IQAir (<https://www.iqair.com/ru/world-air-quality-ranking>).

В то же время Красноярск является одним из российских городов, в которых осуществляется многолетний мониторинг качества атмосферного воздуха на стационарных постах наблюдения, принадлежащих нескольким независимым системам мониторинга. Первичный исследовательский анализ данных от таких систем мониторинга обычно является, с одной стороны, первым шагом для более комплексных исследований, с другой стороны, имеет и самостоятельную ценность, предоставляя статистическое обоснование или опровержение устоявшимся суждениям о сценариях и источниках загрязнений. Такой анализ опубликован для многих мировых промышленных центров (см., например, [1–3]).

В настоящей работе проанализированы многолетние данные, полученные на постах Краевой ведомственной информационно-аналитической системы данных о состоянии окружающей среды Красноярского края (КВИАС). Материалом

¹ Работа поддержана грантом РНФ 24-71-10022.

для статистического анализа послужили данные сети стационарных постов мониторинга за период 01.01.2019 00:00 — 31.12.2025 23:40 (шаг измерений 20 мин). На каждом посту КВИАС регистрируются:

– метеопараметры: температура в приземном слое t , °C; давление на высоте сенсора p , мм рт.ст.; относительная влажность воздуха h , %; скорость ветра ws , м/с; направление ветра wd , в градусах отклонения направления по часовой стрелке от направления на север;

– концентрации следующих газовых и аэрозольных загрязнителей: диоксид азота (NO_2), оксид азота (NO), аммиак (NH_3), сероводород (H_2S), диоксид серы (или сернистый газ, SO_2), оксид углерода (или угарный газ, CO) – все в мг/м^3 , взвешенные частицы $\text{PM}_{2.5}$ (в мкг/м^3).

За обсуждаемый период Среднесибирское УГМС объявляло в г. Красноярске режим неблагоприятных метеоусловий (НМУ) 67 раз. За этот период максимальная продолжительность НМУ составила 192 часа (с 19 часов 27 января 2022 г. по 19 часов 2 февраля 2022 г.). Минимальная продолжительность НМУ составила 24 часа.

Несмотря на многолетний характер наблюдений, в данных присутствует значительное число пропусков, которые связаны либо со сбоями в работе измерительной аппаратуры, либо с периодами её технического обслуживания. Например, самый длительный непрерывный ряд наблюдений за концентрацией $\text{PM}_{2.5}$ составляет лишь 212 дней, то есть менее семи месяцев из семи лет наблюдений. Поскольку наблюдения представлены нестационарными временными рядами, пропуски в них многочисленны, включая длинные последовательности, и асинхронны для разных параметров, то восстановление данных стандартными методами анализа временных рядов невозможно. На рис. 1 приведены временные ряды концентраций всех загрязнителей.




Рис. 1. Графики временных рядов уровней концентрации загрязнителей на посту m_rok (мкрн «Покровка»). Сверху вниз: PM2.5, диоксид азота (NO₂), оксид азота (NO), аммиак (NH₃), сероводород (H₂S), диоксид серы (SO₂), оксид углерода (CO).

В таблице 1 представлена описательная статистика метеопараметров и загрязнителей, рассчитанная по всем постам КВИАС за весь период наблюдения.

Таблица 1. Описательная статистика, рассчитанная по постам КВИАС

Параметр	количество не NA	среднее	стандартное отклонение	min	медиана	max	IQR
t , °C	1638045	3,91	13,46	-40,1	4,20	38,80	20
p , мм рт.ст.	1627256	746,57	9,67	710	746,00	781,90	13
h , %	1637401	67,02	16,20	1	70,00	100,00	22
ws , м/с	1637547	1,24	1,45	0	0,80	16,90	2
PM2.5, мкг/м ³	1314095	17,445	25,244	0	10,00	961,00	14
NO ₂ , мг/м ³	1553929	0,033	0,034	0	0,023	0,859	0,035
NO, мг/м ³	1546087	0,036	0,067	0	0,007	1,118	0,033
NH ₃ , мг/м ³	982919	0,008	0,016	0	0,002	1,220	0,008
H ₂ S, , мг/м ³	1083418	0,001	0,002	0	0,001	0,197	0,002
SO ₂ , , мг/м ³	1675659	0,014	0,023	0	0,007	0,945	0,014
CO, , мг/м ³	1701868	0,448	0,654	0	0,3	83,900	0,400

Анализ метеопараметров. В целом распределения температуры, влажности и давления, рассмотренные по сезонам (зима, весна, лето, осень), близки к нормальным. Дисперсионный анализ по сезонам и оценка доверительных интервалов показывают, что распределение температуры имеет выраженную трехмодальную структуру, соответствующую зиме, лету и межсезонью; при этом зимний сезон характеризуется тяжелым «хвостом» в область низких отрицательных температур, а летом дисперсия заметно меньше. Распределения давления и влажности имеют четырехмодальную структуру, со статистически значимыми различиями между осенью и весной. Для влажности во все сезоны наблюдается выраженная асимметрия с тяжелым «хвостом» влево, то есть в область низкой влажности.

Анализ розы ветров подтверждает известный факт, что в Красноярске преобладают юго-западные и западные ветры. На них приходится более 60 % наблю-

дений; еще по 8 % наблюдений связано с восточным и северо-западным направлениями, в 6 % случаев отмечается штиль, а на остальных четыре направления приходится не более 18 % наблюдений. Направление ветра не демонстрирует заметной зависимости ни от температуры, ни от давления, ни от влажности. Наибольшие скорости ветра характерны преимущественно для западного, а в редких случаях — северного направления, при температурах примерно от $-10\text{ }^{\circ}\text{C}$ до $+10\text{ }^{\circ}\text{C}$.

Анализ коэффициентов корреляции и диаграмм рассеяния метеопараметров показывает, что только температура и давление имеют устойчивую обратную связь. В зимний период давление, как правило, выше, чем в летний. Влажность 100 % достигается при небольших положительных температурах, примерно в диапазоне $8\text{--}12\text{ }^{\circ}\text{C}$. Вместе с тем зимой в Красноярске воздух остается достаточно влажным: относительная влажность не опускается ниже 60 %, а зимняя медиана немного превышает 70 %. Сухие условия наблюдаются лишь в жаркие летние дни. В целом климат города можно охарактеризовать как влажный.

Ряды температуры, давления и влажности характеризуются двумя выраженными сезонными компонентами — годовой и суточной. Суточная компонента играет для выявления погодных паттернов двойственную роль. С одной стороны, суточный ход метеопараметров существенно влияет на процессы накопления и рассеивания загрязняющих веществ и, следовательно, должен учитываться в анализе. С другой стороны, внутрисуточные флуктуации метеопараметров могут маскировать более общие тренды роста и снижения. В связи с этим при дальнейшем более продвинутом анализе целесообразно придерживаться следующих рекомендаций.

Во-первых, данные следует умеренно сглаживать путем осреднения за час. Во-вторых, в анализе предпочтительно использовать не разрозненные часовые наблюдения, а полные суточные профили, то есть рассматривать каждый параметр как точку в 24-мерном признаковом пространстве, а в качестве метки точки использовать дату. Такой подход позволяет одновременно учитывать особенности суточного хода параметра и длительность интервала, естественную с точки

зрения природных и антропогенных процессов. Кроме того, имеет смысл включать в анализ только те сутки, для которых доступны все 72 наблюдения. Это дополнительно повышает качество данных, поскольку выбросы нередко располагаются вблизи цепочек пропусков, возникающих при сбоях датчиков.

Кроме того, метеопараметры содержат неочевидную, не выявляемую простыми методами циклическую, хотя и не строго периодическую, составляющую, связанную с режимами синоптического процесса, такими как циклон, антициклон, фронтальные разделы и барические экстремумы. Эти режимы существенно влияют на процессы накопления и рассеивания загрязняющих веществ. К сожалению, имеющегося набора метеопараметров недостаточно для выделения с помощью статистических методов и методов анализа данных, включая кластеризацию и построение классификаторов, синоптических паттернов, способствующих накоплению загрязнений. По-видимому, для повышения информативности анализа необходимо обогатить набор данных сведениями об облачности, осадках и синоптических режимах. В этом случае исследование метеопараметров можно будет провести более точно и содержательно.

Анализ концентраций загрязнителей. Мы проанализировали многолетнюю динамику концентраций шести газообразных загрязнителей: NO_2 , NO , NH_3 , H_2S , SO_2 , CO , а также мелкодисперсных взвешенных частиц $\text{PM}_{2.5}$, представляющих фракцию атмосферного аэрозоля. Концентрации загрязнителей определяются совместным воздействием источников выбросов, атмосферного переноса, метеорологических условий и химических превращений в атмосфере. Оксид азота обычно со скоростью, зависящей от метеообстановки доокисляется до диоксида азота NO_2 и их в анализе часто объединяют под названием NO_x .

У CO и NO_x источники во многом совпадают – бензиновые и дизельные двигатели, котельные, ТЭЦ, промышленные печи и бытовое отопление. Однако CO – это продукт неполного окисления углерода, т.е. образуется при недостатке кислорода, малых температурах или плохом перемешивании топлива с воздухом. NO_x наоборот продукт горения при больших температурах, избытке кислорода, а

также зависит от наличия в топливе азота. Хотя СО связывают с плохо прогретыми двигателями, бытовыми печами с плохой тягой, а NO_x – с высокотемпературными промышленными установками, в продуктах горения все эти компоненты присутствуют одновременно, но в разных пропорциях. Диоксид серы SO_2 тоже образуется при сжигании, но серосодержащего топлива, его источники промышленные предприятия, они, чаще всего, локальны и стационарны.

Первичные частицы $\text{PM}_{2.5}$ в промышленном городе чаще всего также связаны с источниками горения – двигателями, печами бытового отопления, котельными, промышленными установками. Кроме того, в атмосфере из газообразных прекурсоров, включая NO_x , NH_3 , SO_2 и летучих органических соединений образуются вторичные частицы $\text{PM}_{2.5}$. Концентрация $\text{PM}_{2.5}$ имеет обычно не конкретный источник, а является результатом выбросов, переноса, накопления загрязняющих веществ и их химических реакций.

Аммиак NH_3 и сероводород H_2S в условиях города связаны с хранением и разложением органических отходов, канализацией, очистными сооружениями. Эти загрязнители имеют, как правило, локальные источники.

Максимальные значения концентраций всех анализируемых загрязнителей в г. Красноярск превышают соответствующие разовые ПДК, но медианные значения все-таки меньше ПДК. Кроме того, в последние три года в Красноярске наблюдается уменьшение среднегодовых и медианных концентраций таких загрязнителей, как аммиак (NH_3) и сероводород (H_2S), а также взвешенных частиц $\text{PM}_{2.5}$. Среднегодовые и медианные концентрации других проанализированных загрязнителей в последние три года, по крайней мере, не растут.

Для всех загрязнителей распределение 20-минутного усреднения, по сути, состоит из двух частей. Во-первых, это нулевые измерения, когда концентрация загрязнителя оказывается ниже порога чувствительности прибора. Доля нулей составляет от 5 % для $\text{PM}_{2.5}$ до 40 % и, на некоторых постах, даже 60 % для NH_3 и H_2S . Это дает большой пик на гистограмме в начале распределения. Даже при логарифмировании данных с заменой нуля на какое-нибудь малое положительное значение, распределение остается неестественно скошенным в малые значения.

Во-вторых, это измерения, имеющие положительное непрерывное распределение (которое на основе принципа максимального правдоподобия определялось для разных загрязнителей близким к логнормальному, гамма или Вейбулла).

Корреляционный анализ. Был проведен анализ диаграмм рассеивания и подробный корреляционный анализ загрязнителей между собой, а также между загрязнителями и метеопараметрами. Анализ проводился отдельно на каждом посту как для каждого сезона, так и сразу по всем наблюдениям.

Несмотря на то, что распределения загрязнителей существенно отклоняются от нормального, для оценки связи использован коэффициент корреляции Пирсона. Это корректно по двум причинам. Во-первых, объем данных у нас достаточный, чтобы использовать параметрический метод. Во-вторых, 20-минутные данные имеют большие случайные флуктуации, что неизбежно занижит ранговый коэффициент корреляции Спирмена как непараметрическую меру монотонной зависимости. Однако, мы убедились, что результаты параметрического и непараметрического анализа не противоречат друг другу. В исследовании был принят уровень значимости $\alpha=0.05$.

Сначала были рассчитаны коэффициенты попарной корреляции r . Только четыре загрязнителя – PM2.5, CO, NO и NO₂ – устойчиво сильно или умеренно коррелируют между собой, а также с температурой и скоростью ветра.

Далее для этих четырех загрязнителей были рассчитаны частные коэффициенты корреляции как коэффициенты корреляции между остатками множественных линейных регрессий. Таким образом, для каждой пары загрязнителей из их концентраций предварительно исключалась составляющая, линейно связанная с двумя оставшимися загрязнителями. Например, частная корреляция NO и NO₂ при контроле CO и PM2.5 определялась как корреляция между остатками регрессий $NO \sim CO + PM2.5$ и $NO_2 \sim CO + PM2.5$. Коэффициент такой частной корреляции далее будем обозначать через $r(NO, NO_2 | \{PM2.5, CO\})$. Дополнительно для каждой пары были рассчитаны частные корреляции при контроле не только оставшихся загрязнителей, но и основных метеопараметров. Отметим, что некоторые

закономерности уверенно проявляются независимо от сезонов, а другие наблюдаются только в определенные времена года. Ниже описаны основные результаты.

1. Наблюдается устойчивая корреляция между PM2.5 и CO: на всех постах при парной корреляции $r(\text{PM2.5}, \text{CO})$ около 0,85 частная корреляция $r(\text{PM2.5}, \text{CO} | \{\text{NO}, \text{NO}_2, t, \text{ws}\})$ остается на уровне 0,6.

2. На большинстве постов наблюдается слабая корреляция между CO и NO: $r(\text{CO}, \text{NO})$ и $r(\text{CO}, \text{NO} | \{\text{PM2.5}, \text{NO}_2, t, \text{ws}\})$ около 0,35. На половине постов сохраняется слабая корреляция между CO, NO₂, правда соответствующие коэффициенты корреляции не превышают 0,25.

3. На большинстве постов наблюдается парная корреляция между NO и NO₂: $r(\text{NO}, \text{NO}_2)$ до 0,6. В то же время контроль CO и метеопараметров снижает коэффициент корреляции почти вдвое: $r(\text{NO}, \text{NO}_2 | \{\text{PM2.5}, \text{CO}, t, \text{ws}\})$ становится около 0,3.

4. Наблюдающаяся парная корреляция между PM2.5 и оксидами азота NO_x при контроле остальных загрязнителей и метеопараметров пропадает.

5. Интересно, что проявляющаяся парная корреляция между загрязнителями и метеопараметрами исчезает при контроле других загрязнителей и метеопараметров. Очень слабая корреляция (на уровне 0,25) остается только между NO₂ и скоростью ветра.

В целом корреляционный анализ показывает следующее. Комплекс загрязнителей {CO, NO_x} имеют общий или частично общий источник, связанный с процессами сжигания топлива (по всей вероятности, транспортом и отоплением). Связь NO с NO₂ отражает совместное поступление этих веществ и общий режим накопления. В то же время химическое превращение NO в NO₂ явно является дополнительным, не выделяемым по имеющимся данным механизмом. PM2.5 связан с этим комплексом {CO, NO_x} через CO, однако его концентрация дополнительно определяется накоплением и вторичным образованием аэрозоля, поэтому линейная связь между PM2.5 и NO_x не обнаруживается.

И наконец, наличие парных корреляционных связей между основными метеопараметрами и загрязнителями и их полное исчезновение в частных корреляциях при контроле другими загрязнителями можно считать обоснованием тривиального утверждения, что нет какого-то одного условия повышения концентрации загрязняющих веществ в приземном слое атмосферы города.

Список литературы

1. Bose A. Investigating the association between air pollutants' concentration and meteorological parameters in a rapidly growing urban center of West Bengal, India: a statistical modeling-based approach / Bose, A., Roy Chowdhury, I. // Model. Earth Syst. Environ. – 2023. – V. 9. – P. 2877–2892.
2. Li X. Long-Term Air Pollution Characteristics and Multi-scale Meteorological Factor Variability Analysis of Mega-mountain Cities in the Chengdu-Chongqing Economic Circle / Li X, Abdullah LC, Sobri S, Md Said MS, Hussain SA, Aun TP, Hu J. // Water Air Soil Pollut. – 2023. – V. 234(5). – Article 328.
3. AlQahtani A.I. Air quality levels in the industrial city of Jubail, Saudi Arabia / AlQahtani A.I., Salama K.F., Alwadei M.M., Aljassim M.T., Alsaif A.S., Al-Warthan M. and AlMulla A.A. // Frontiers in Environmental Engineering. – 2024. – V. 3. – Article 1483568.
4. Karepova E. Temporal patterns of instrumentation failures in atmospheric boundary layer observational systems / E. Karepova, Y. Shan'ko, A. Tokarev, V. Petrakova. // E3S Web of Conferences. – 2025. – V. 646. – Article 00011.

СВЯЗЬ СХОДСТВА СТИМУЛОВ ВНЕШНЕЙ СРЕДЫ И СООТВЕТСТВУЮЩИХ ВНУТРЕННИХ СОСТОЯНИЙ НЕЙРОСЕТЕВЫХ МОДЕЛЬНЫХ ОБЪЕКТОВ

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. Интерес представляют вопросы, связанные с конкретным воплощением рефлексии, в частности, как могут быть устроены модели мира и отдельных его элементов [4, 5], реализуемые в некотором пространстве внутренних состояний организма.

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 [6, 7]. Применимость объектов такого типа для моделирования когнитивных функций и, в частности, рефлексии обоснована в нашей работе [8].

Для формирования репрезентаций внешнего мира необходимо поместить эвристический модельный объект в соответствующие условия, которые имитируют внешнюю среду, влияющую на объект посредством стимулов. Таким условием является наличие потока дискретных событий (стимулов), которые предъявляются модельному объекту, и он формирует на каждое событие отклик, адекватность (правильность) которого оценивается по заранее заданному правилу.

Например, объект реагирует на один из нескольких возможных фиксированных последовательностей стимулов (временных рядов), для чего необходимо распознать каждый ряд при его подаче с помощью внутреннего представления о нем [9]. Имеющиеся в среде ряды могут в той или иной степени совпадать друг с другом, что затрудняет распознавание, и задача модельного объекта сформировать представления о них, позволяющие всё же решить задачу.

Настоящая работа посвящена вопросу о том, наблюдается ли сходство внутренних состояний модельных объектов – рекуррентных нейронных сетей (РНС) при обработке схожих временных рядов стимулов.

В работе использовались гомогенные РНС без отдельных слоев входа и выхода, 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. РНС данного типа использовались нами в предыдущих работах [8-10]. Рекуррентность необходима, поскольку благодаря такой структуре сети нейронов возможно автономное существование внутренних репрезентаций предшествующих состояний рецепторов [11,12], что является необходимым для решения поставленной перед РНС задачи.

Рассматривались РНС из 6, 10, 15, 20, 25 и 30 нейронов. Начальные веса РНС задавались случайным образом в диапазоне (-0.050; 0.050). РНС обучались задаче реагирования на четыре фиксированных временных ряда стимулов (кратко – ряды), представляющие собой последовательности стимулов «0» и «1» с повторяющимися сегментами длины 6 (см. Таблицу).

Для РНС стандартного типа (SRN), отклик на текущем такте должен был соответствовать сигналу, получаемому на вход (аналогично позиции «чет» в игре чет-нечет). Стимул «0» подавался на два входа SRN как 01, «1» - как 10. Отклик SRN определялся похожим образом по соотношению сигналов на двух выходных нейронах.

Для РНС типа NoInp, отклик на текущем такте должен был соответствовать

текущему символу ряда, при этом единичный входной сигнал подавался только однократно при смене ряда, на тот вход из четырех, который соответствовал номеру этого ряда. Отклик NoInp также определялся по соотношению сигналов на двух выходных нейронах.

Таблица
Временные ряды стимулов

№ ряда	1	2	3	4
Сегмент	101011	101100	010011	111000

Обучение РНС составляло 100 000 тактов и происходило по алгоритму backprop с глубиной распространения 5 тактов и квадратичной функцией потерь. Продолжительность подачи одного ряда до смены на другой, выбранный случайно, задавалась равной либо всегда 30 тактам (режим FixL), либо случайно выбранному количеству от 24 до 36 тактов (режим VarL). После обучения качество воспроизведения рядов проверялось в тестах, где те же ряды менялись в случайном порядке, а продолжительность подачи каждого составляла либо от 24 до 36, либо ровно 30 тактов. Веса РНС оставались модифицируемыми (тест модиф) либо фиксировались сразу после обучения (тест фикс).

Показано, что для РНС обоих типов увеличение размера сети с 10 до 30 нейронов не приводит к повышению качества отклика (Рис.1): для обоих типов РНС и всех тестов между 10- и 30-нейронными РНС либо нет значимых различий в точности отклика, либо 10-нейронные показывают значимо лучший результат (использован непараметрический критерий Вилкоксона-Манна-Уитни, $\alpha=0,01$, $N=30$). РНС типа SRN, обученные в режиме VarL, показывают лучшие результаты в тестах, чем SRN, обученные в режиме FixL, а для NoInp различий между режимами не обнаружено. При этом точность отклика SRN10 выше, чем у NoInp10, следовательно, у РНС этого типа формируются более адекватные с точки зрения функционирования внутренние представления рядов, и именно они исследовались далее.

Из групп SRN10 FixL и SRN10 VarL были выбраны по три наиболее успеш-

ных (лучшие) и наиболее неуспешных (худшие) РНС, для каждой записаны сигналы на нейронах при получении рядов в течение 300 тактов каждый, веса РНС фиксированы. Были рассчитаны евклидовы расстояния между состояниями РНС (т.е. сигналами на нейронах) для всех пар рядов, что позволяет оценить сходство состояний РНС, соответствующих этим рядам. Данные расстояния усреднялись по 6 последним тактам получения рядов. Аналогично рассчитывались расстояния между сегментами самих рядов (см. Таблицу) для оценки сходства между ними. Показано, что SRN10 VarL, независимо от успешности, демонстрируют совпадение сходства рядов и возникающих при их обработке состояний РНС, что для SRN10 FixL наблюдается реже (Рис.2).




Рис.1. Точность отклика РНС типа NoInp и SRN при тестировании
($W_{кр} = 2,6$; $\alpha = 0,01$).




Рис.2. Расстояния между рядами стимулов и состояниями РНС, возникающими при обработке этих рядов (нормированы на максимально возможное расстояние, равное 6). Погрешности – стандартное отклонение для расстояний между состояниями РНС, усреднение по 6 тактам обработки каждого ряда.

Были рассчитаны величины структурных характеристик SRN10 VarL и FixL: норма матрицы весов, которая характеризует нарастание значений весов в результате обучения, и максимальное собственное значение Якобиана правой части уравнений (1), описывающих функционирование РНС, которое характеризует тип аттрактора нейронной активности для невозбужденного состояния. Показано, что средние значения обеих характеристик оказываются ниже у SRN10 VarL, чем у SRN10 FixL; при этом не обнаружено корреляций между этими значениями и суммарной точностью отклика РНС в тестах (Рис.3).




Рис.3. Диаграммы рассеяния для формальной (точность отклика в тестах) и структурной характеристик SRN10.

Итак, в настоящей работе:

1) определены минимальный размер и тип РНС, при которых наблюдается наибольшая точность в тестах: 10-нейронная SRN. Показано, что как с точки зрения точности, так и структурных характеристик, имеет существенное значение, поступают ли ряды стимулов при обучении РНС в течение всегда одинакового количества тактов (30), или оно выбирается каждый раз случайно в некотором диапазоне (24-36). Лучшие результаты наблюдаются при обучении с переменным количеством тактов;

2) для наиболее эффективной конфигурации РНС (10-нейронная SRN, обученная при переменной продолжительности подачи рядов) продемонстрировано сходство внутренних состояний при обработке схожих временных рядов стимулов. Следовательно, отражение входных стимулов на состояние РНС в данном случае реализуется с сохранением «пропорций» исходных стимулов друг относительно друга.

Полученные результаты дополняют картину того, как формируются внутренние представления внешних стимулов среды, т.е. как реализуется рефлексия в широком смысле, на примере эвристических нейросетевых модельных объектов.

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.Pezulo // *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. Friston K. World model learning and inference / K.Friston, R.J.Moran, Y.Nagai, T.Taniguchi, H.Gomi, J.Tenenbaum // *Neural Networks*. – 2021. – Vol. 144. – P. 573-590.
5. Zhao P. Bridging the reality gap: A benchmark for physical reasoning in general

- world models with various physical phenomena beyond mechanics / P.Zhao, J.Xu, N.Cheng, H.Hu, X.Zhang, X.Xu, Z.Jin, F.Meng, J.Zhou, W.Han // *Expert Systems with Applications*. – 2025. – Vol. 270. – P. 126548.
6. Baciuc D. C. Neural networks through the lens of evolutionary dynamics / D.C.Baciuc // *BioSystems*. – 2025. – Vol. 248. – P. 105386.
 7. 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.
 8. 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.
 9. Markova G. M. Equifinality of Reflection in the Limit World Model Tasks / G.M.Markova, S.I.Bartsev // In: *Advances in Neural Computation, Machine Learning, and Cognitive Research IX. NEUROINFORMATICS 2025*. Eds. B.Kryzhanovsky, W.Dunin-Barkowski, V.Redko, Y.Tiumentsev, V.V.Klimov // Springer, Cham. – 2026. – Vol. 1241. – P. 563–575.
 10. Маркова Г.М. Формирование универсального навыка рефлексии в условиях предельных моделей мира / Г.М. Маркова, С.И. Барцев // *Информационные и математические технологии в науке и управлении*. – 2026. – № 2(42). – С. 18–28.
 11. 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.
 12. 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.

ЭКСПЕРИМЕНТАЛЬНАЯ АПРОБАЦИЯ МЕТОДИКИ АВТОМАТИЗИРОВАННОЙ ОЦЕНКИ УРОВНЯ РАЗВИТИЯ КОМПЕТЕНТНОСТЕЙ ПО ЗАДАНИЯМ С ВОПРОСАМИ ОТКРЫТОЙ ФОРМЫ

Е.Л. Матинина, В.А. Углев

Сибирский федеральный университет,

Институт космических и информационных технологий, Межинститутская базовая кафедра «Прикладная физика и космические технологии», uglev-v@yandex.ru

Внедрение компетентного подхода требует оценки не только знаний, но и способности применять их в нестандартных ситуациях [1, 2], однако традиционные закрытые формы заданий (в первую очередь, в форме тестов) не позволяют диагностировать большинство компетенций [3], а задания (вопросы) открытой формы, обладая высокой валидностью, трудно поддаются автоматической проверке из-за вариативности формулировок и нечеткости критериев. В связи с этим целью исследования является разработка методики автоматизированной оценки уровня развития компетентностей по заданиям открытой формы, которая сохраняет преподавателя в роли источника экспертного знания, минимизирует субъективизм интерпретации ответов и, при этом, интегрирует результаты в единый компетентностный профиль [4]. Предлагаемый подход сочетает экспертный анализ, выполняемый преподавателем, с вычислительными алгоритмами проверяющей системы [3], опираясь на интеллектуальный механизм проверки гипотез.

Разработанная методика представляет собой последовательный процесс, в котором ключевая роль отводится преподавателю как источнику экспертного знания, а автоматизированная система выступает в роли инструмента сбора, обработки и визуализации данных [5]. Методика состоит из 6 последовательно выполняемых этапов.

На первом этапе преподаватель наполняет базу данных вспомогательными гипотезами: задаёт эталонные варианты ответов и определяет, какие компетенции и в какой степени они подтверждают, а также наборы экспертных оценок, связывающих варианты ответов с компетенциями. На втором этапе создаётся вопрос

открытого типа с привязкой к вспомогательным гипотезам, что закладывает основу для последующей автоматизированной оценки. На третьем этапе преподаватель комплектует тест, включая в него вопросы закрытого и открытого типа для охвата широкого спектра компетенций. На четвертом этапе учащиеся решают тест: ответы на вопросы закрытого типа фиксируются автоматически, а задания открытой формы сохраняются в виде текста для последующей проверки. На пятом этапе преподаватель оценивает свободную формулировку ответов, сопоставляя их с вспомогательными гипотезами и переводя в формализованный вид для системы из [3]. На заключительном (шестом) этапе система автоматически рассчитывает компетентностный профиль, агрегируя данные с помощью критерия Шортлиффа [6], после чего визуализирует результат в виде лепестковой диаграммы.

Для проведения эксперимента используется модифицированная версия программной системы AESU [7]. Ключевым дополнением, в рамках данного исследования, стал модуль поддержки заданий открытой формы [8]: интерфейс ввода развернутых ответов студентами, панель преподавателя-эксперта с привязкой к вспомогательным гипотезам и с автоматизированным расчетом компетентностного профиля. Оценивание проводилось по восьми компетенциям, включающим профессиональные (например, «Демонстрировать владение системным подходом», «Искать, обобщать и структурировать информацию») и личностные качества («Иметь широкий кругозор», «Чётко выполнять инструкции задания»).

В рамках проведения эксперимента был составлен банк заданий, с помощью которого в дальнейшем проведена итоговая контрольная работа обучающихся и оценка ответов. Банк заданий представляет из себя 10 заданий с возможностью ответов открытого типа. Эксперимент проведен на базе Межинститутской базовой кафедры «Прикладная физика и космические технологии» СФУ (г. Железногорск). Участники — 25 студентов первого курса магистратуры групп КИ25-01-3М и МТ25-04М направления 09.04.01 «Информатика и вычислительная техника».

Процедура включала три этапа [6]:

1 Решение студентами контрольной работы (только открытые вопросы, без ограничения времени, запрет внешних источников, опция «Затрудняюсь ответить»).

2 Оценка преподавателем каждого развернутого ответа по вспомогательным гипотезам.

3 Автоматический расчет и визуализация компетентностного профиля.

В ходе экспериментальной апробации разработанной методики был выполнен анализ компетентностных профилей на индивидуальном и групповом уровнях.

Прежде всего, необходимо охарактеризовать начальное состояние, относительно которого оценивалась динамика уровня развития компетентностей. Исходной точкой эксперимента выступал «нулевой» компетентностный профиль, при котором значения всех компетенций находились в зоне неопределённости (равны 0). Данное состояние отражало отсутствие у системы уверенности в сформированности компетенций у обучающихся до начала эксперимента. Этот профиль послужил своего рода «точкой отсчёта» для всех последующих измерений. Нулевой компетентностный профиль представлен на рисунке 1.




Рис. 1. Визуальное представление исходного компетентностного профиля

Профиль включает следующие показатели, расположенные по осям диаграммы:

ПК1 – Демонстрировать владение системным подходом (анализ и синтез);

ПК2 – Искать, обобщать, концентрировать и структурировать информацию, выделять существенное, делать выводы;

ПК3 – Владеть способностью формулировать содержательные задачи исследования, выбирать методы экспериментального и вычислительного экспериментов;

ПК4 – Владеть способностью готовить научно-технические отчеты, обзоры и публикации по результатам выполненных исследований, оформлять, представлять и докладывать результаты выполненной научно-исследовательской работы;

ПК5 – Уметь уместно использовать общую и специальную терминологию при формулировании письменных ответов;

Д1 – Иметь широкий кругозор;

Д2 – Чётко и полно выполнять инструкции заданий, учитывать образцы и требования к ответу.

Переходя к анализу различий компетентностных профилей, полученных по результатам решения заданий отдельными обучающимися, можно констатировать следующее: наблюдается высокая дифференцирующая способность разработанной методики. В качестве иллюстрации приведём два случая. У студента с низкими результатами ответы были краткими, поверхностными либо содержали отметку «Затрудняюсь ответить», его компетентностный профиль остался вблизи нулевых значений (рис. 2, слева). Напротив, студент с высокими результатами продемонстрировал аргументированные развёрнутые ответы с использованием профессиональной терминологии и логической завершённостью, что и нашло отражение на правом профиле с рис. 2.




Рис. 2. Компетентностный профиль обучающегося, показавшего низкие (слева) и высокие (справа) результаты

Помимо индивидуального анализа, важное значение имеет сравнение результатов на уровне учебных групп. Анализ групповых профилей для учебных групп КИ25-01-3М и МТ25-04М выявил существенные различия в уровне подготовки. Группа КИ25-01-3М показала значительно большую площадь профиля и вытянутые «лепестки», что свидетельствует о более высоком среднем уровне развития компетентностей. Группа МТ25-04М, напротив, продемонстрировала более компактный профиль со значениями, приближёнными к границе неопределённости, что указывает на недостаточное освоение учебного материала. Компетентностные профили этих групп представлены на рисунке 3. Следовательно, методика позволяет выявлять не только индивидуальные, но и групповые различия в уровне сформированности компетентностей.




Рис. 3. Компетентностный профиль надпредметной оценки обучающихся группы КИ25-01-3М (слева) и МТ25-04М (справа).

Для проверки согласованности предлагаемой методики с традиционно используемым подходом (оценкой исключительно по заданиям закрытой формы) было организовано тестирование (35 вопросов). Далее был проведён корреляционный анализ полученных результатов на контрольной и тесте. Для группы КИ25-01-3М коэффициент корреляции составил 0.624, для группы МТ25-04М — 0.864. Среднее значение коэффициента корреляции по двум группам достигло 0.744. Данная процедура позволила констатировать то, что предложенная методика работает не хуже, чем та, которая опирается исключительно на задания закрытой формы. На рисунках 4 и 5 представлена диаграмма оценок компетентностей по результатам теста (синим) и контрольной (оранжевым) для групп КИ25-01-3М и МТ25-04М, соответственно.




Рис. 4. Диаграмма оценок компетентностей для группы КИ25-01-3М




Рис. 5. Диаграмма оценок компетентностей для группы МТ25-04М.

Обобщая представленные результаты, можно сделать вывод, что разработанная методика обладает высокой дифференцирующей способностью; достаточно надёжно фиксирует различия как между отдельными учащимися, так и между учебными группами; демонстрирует сильную корреляцию с эталонными измерениями (средний коэффициент 0,744) и успешно воспроизводится на материале разных дисциплин.

Список литературы

1. Аванесов В. С. Композиция тестовых заданий. — М.: Центр тестирования, 2018.
2. Переверзев В. Ю. Критериально-ориентированное педагогическое тестирование. — М.: Логос, 2003.
3. Пронин А.Д. Сервис автоматизации надпредметной проверки уровня развития компетентностей // Преподавание информационных технологий в Российской Федерации: Материалы XX Всероссийской конференции. - Москва: МФТИ, 2021. – С. 207 - 209.
4. Uglev V., Shangina E. Assessment and visualization of course-level and curriculum-level competency profiles // Computational Science and Its Applications – ICCSA 2023 Workshops. LNCS, vol 14104. Springer, Cham. pp. 478–493. https://doi.org/10.1007/978-3-031-37105-9_32.
5. Углев В. А., Добронев Б. С. Методика автоматизированного измерения и оценки уровня развития компетентностей // Информатика и образование. — 2017. — № 2. — С. 61–65.
6. Shortliffe E. H., Buchanan B. G. A model of inexact reasoning in medicine // Mathematical Biosciences. — 1975. — Vol. 23, № 3-4. — P. 351–379.
7. Смирнов Г.А., Пронин А.Д., Кузнецов М.В., Углев В.А. Механизмы работы интеллектуальной автоматизированной обучающей системы AESU // Нейроинформатика, ее приложения и анализ данных: XXXIII Всероссийский семинар. – Красноярск: ИВМ СО РАН, 2025. – С. 121-131.
8. Матинина Е. Л., Углев В. А. Программная реализация экспертно-автоматизированной методики оценивания ответов на задания открытого типа // Потенциал устойчивого инновационного развития. – Уфа: Омега сайнс, 2026. – С. 54–61.

ФАКТОРНАЯ СТРУКТУРА ИММУНИТЕТА У ЗДОРОВЫХ ЛЮДЕЙ

А.С.Михалев¹, И.С.Садовский², А.А.Савченко², С.А. Борисов³, А.Г.Борисов²

¹Сибирский федеральный университет,

Институт космических и информационных технологий,

² НИИ медицинских проблем Севера – обособленное подразделение ФИЦ КНЦ

СО РАН, Красноярск

³КГБУЗ «Красноярская межрайонная клиническая больница № 20 имени И.С.

Берзона», Красноярск

Иммунная система человека представляет собой сложную многокомпонентную сеть клеточных и гуморальных элементов, функционирующих согласованно и обеспечивающих поддержание иммунного гомеостаза. Даже у клинически здоровых людей иммунологические показатели характеризуются выраженной межиндивидуальной вариабельностью, при этом значительная часть этой вариабельности отражает не патологию, а естественные особенности организации иммунного ответа [1-3].

Современные исследования в области системной иммунологии показывают, что иммунный профиль здорового человека не сводится к набору независимых лабораторных показателей, а формируется за счет координированных сочетаний клеточных субпопуляций и интегральных иммунологических признаков [1, 4]. При этом возраст, пол, особенности среды и индивидуальная история антигенных воздействий способны существенно влиять на распределение иммунных клеток и их соотношения даже в пределах условной нормы.

В связи с этим особую актуальность приобретает поиск скрытой, или латентной, структуры иммунологических показателей у здоровых лиц. Факторный анализ является одним из наиболее подходящих статистических инструментов для решения этой задачи [5], поскольку позволяет сократить размерность данных, выделить устойчивые взаимосвязанные блоки признаков и перейти от анализа отдельных параметров к анализу интегральных компонентов иммунной организации. Такой подход особенно важен в иммунологии, где многие показатели биоло-

гически и статистически зависимы друг от друга, а интерпретация каждого маркера по отдельности часто оказывается ограниченной.

Несмотря на значительный интерес к вариабельности иммунного профиля в норме, большинство работ сосредоточено либо на описании референсных диапазонов отдельных иммунологических параметров, либо на изучении возрастных, половых и средовых различий. В то же время вопрос о том, какие именно латентные компоненты лежат в основе совместной изменчивости стандартных показателей иммунного статуса у здоровых взрослых, остается изученным недостаточно. Выделение таких факторов может способствовать более точному пониманию внутренней организации иммунной системы и создать основу для последующего сравнения нормы с патологическими состояниями.

Цель настоящего исследования заключается в выявлении латентной структуры стандартных показателей иммунного статуса у клинически здоровых взрослых с использованием методов многомерного статистического анализа. Предполагалось, что совокупность взаимосвязанных иммунологических показателей может быть представлена ограниченным числом латентных факторов, отражающих основные компоненты организации иммунного профиля. Выделение таких факторов позволяет перейти от анализа отдельных лабораторных показателей к интегральному представлению состояния иммунной системы и создать основу для последующего сопоставления нормы и патологических состояний.

Характеристика исходных данных

Исходная база данных содержала сведения о 344 **клинически здоровых** обследуемых. Средний возраст составил $35,2 \pm 13,3$ года, медиана – 34 года, межквартильный разброс ($Q1 - Q3$) 23 – 44 года, диапазон – 18 – 67 лет. Половая структура - 202 женщины (58,7%) и 142 мужчины (41,3%).

В факторный анализ были включены 11 количественных показателей иммунного статуса: количество лейкоцитов, абсолютное содержание гранулоцитов, сегментоядерных нейтрофилов, эозинофилов, моноцитов и лимфоцитов, а также абсолютное содержание Т-лимфоцитов, Т-хелперов, Т-эффекторных лимфоци-

тов, В-лимфоцитов и NK-клеток. Выбор признаков был обусловлен их представленностью в исходной базе данных, достаточной полнотой наблюдений и возможностью охарактеризовать основные клеточные звенья иммунной системы.

Перед проведением многомерного анализа записи с полностью отсутствующими исследуемыми показателями удалялись. Дополнительно исключались наблюдения, в которых отсутствовало более 50% включенных в анализ признаков. После применения критериев отбора аналитическая выборка составила 344 наблюдения.

Для восстановления отдельных пропущенных значений применялась итеративная многомерная импутация по схеме MICE [6]. На начальном этапе пропуски инициализировались медианными значениями соответствующих показателей, после чего выполнялось последовательное прогнозирование недостающих значений с учетом остальных признаков.

После обработки пропусков все показатели были стандартизированы. Такое преобразование выравнивает вклад переменных, измеряемых в различных единицах, и предотвращает доминирование показателей с большими абсолютными значениями в факторном и компонентном анализе.

Методы и модели

Для непосредственного выявления факторной структуры применялся классический факторный анализ на основе общей ковариационной матрицы стандартизированных показателей.

Пригодность данных для факторного анализа оценивалась с использованием меры выборочной адекватности Кайзера–Мейера–Олкина и критерия сферичности Бартлетта [7, 8]. Общий показатель КМО составил 0,535, что соответствует минимально приемлемому уровню факторизуемости данных. Критерий сферичности Бартлетта выявил статистически значимое отличие корреляционной матрицы от единичной ($\chi^2 = 9081,69$; $df = 55$; $p < 0,001$), что свидетельствует о наличии выраженных корреляционных связей между исследуемыми показателями и допускает применение факторного анализа.

Число латентных факторов оценивали на основании собственных значений

корреляционной матрицы и параллельного анализа Хорна (рисунок 1). Согласно критерию Кайзера [9], собственное значение выше 1 имели первые три компоненты ($\lambda_1 = 5,414$; $\lambda_2 = 2,074$; $\lambda_3 = 1,371$), тогда как собственное значение четвертой компоненты составляло 0,811. Параллельный анализ Хорна также рекомендовал сохранение трех факторов [10].




Рис. 1. Определение числа латентных факторов на основании собственных значений и параллельного анализа Хорна

Первые три наблюдаемые собственные значения превышали как единицу в соответствии с критерием Кайзера, так и соответствующие 95-е перцентили собственных значений случайных матриц. Начиная с четвертой компоненты наблюдаемые собственные значения находились ниже случайного порога. Таким образом, оба критерия согласованно указывали на выделение трех латентных факторов.

Полученная матрица факторных нагрузок представлена на рис. 2. Она отражает характер и направление связи каждого исследуемого иммунологического показателя с выделенными латентными факторами.




Рис.2. Матрица факторных нагрузок иммунологических показателей по результатам классического факторного анализа

Результатом факторного анализа явились матрицы факторных нагрузок, отражающие степень связи каждого показателя с соответствующим фактором. Высокие положительные нагрузки интерпретировались как прямое участие признака в латентном компоненте, отрицательные нагрузки – как обратная связь с фактором.

Для содержательной интерпретации факторов учитывались показатели с абсолютным значением факторной нагрузки не менее 0,40. Положительные нагрузки характеризовали однонаправленную связь показателя с латентным фактором, отрицательные – противоположное направление связи. Основные факторные нагрузки и их биологическая интерпретация представлены в таблице 1.

Таблица 1

Структура и биологическая интерпретация латентных факторов иммунного профиля здоровых обследуемых

Фактор	Основные нагрузки	Интерпретация
--------	-------------------	---------------

1	лейкоциты 0,988; гранулоциты 0,885; нейтрофилы 0,790; лимфоциты 0,668; моноциты 0,653; Т-лимфоциты 0,599; эозинофилы 0,597; Т-хелперы 0,509; Т-эффекторы 0,453; В-лимфоциты 0,439; NK-клетки 0,423	Общий клеточный (лейкоцитарно-лимфоцитарно-гранулоцитарный) компонент периферической крови
2	лимфоциты -0,613; нейтрофилы 0,590; Т-лимфоциты -0,579; Т-хелперы -0,521; Т-эффекторы -0,487; гранулоциты 0,458	Нейтрофильно-гранулоцитарный компонент, отражающий баланс врожденного и адаптивного клеточного звеньев
3	моноциты 0,658; эозинофилы 0,622; Т-хелперы -0,445; лимфоциты -0,421; Т-лимфоциты -0,410	Моноцитарно-эозинофильный компонент, характеризующийся противоположной направленностью относительно лимфоцитарно-Т-клеточного контура

На основании суммы квадратов факторных нагрузок первый фактор характеризовал 43,7% общей стандартизованной дисперсии исследуемых показателей, второй – 20,7%, третий – 15,1%. Суммарная доля общей стандартизованной дисперсии, характеризуемая трехфакторным решением, составила 79,4%.

Для дополнительного сопоставления структуры данных применялся метод разреженного анализа главных компонент (Sparse PCA) [11], представляющий собой регуляризованный вариант анализа главных компонент. Число компонент задавалось равным трем в соответствии с результатами критерия Кайзера и параллельного анализа Хорна. В расчетах использовался коэффициент регуляризации $\alpha = 0,001$. При выбранном значении параметра регуляризации доля нулевых нагрузок составила 0%, поэтому Sparse PCA использовался преимущественно как дополнительный способ сопоставления структуры компонент с результатами классического факторного анализа. Полученная матрица нагрузок Sparse PCA представлена на рисунке 3.




Рис.3. Матрица нагрузок иммунологических показателей по результатам разреженного анализа главных компонент

Сравнение матриц нагрузок Sparse PCA с результатами классического факторного анализа показало частичное сходство структуры выделенных компонент (рис. 3). Первый компонент преимущественно отражал общий клеточный профиль, второй – противопоставление гранулоцитарных и лимфоцитарных показателей, третий – моноцитарно-эозинофильное направление. Для количественной оценки сходства решений использовали коэффициент конгруэнтности Такера [12]; средняя абсолютная конгруэнтность соответствующих компонент составила 0,772. Полученное значение свидетельствует о частичном соответствии двух решений, поэтому результаты Sparse PCA рассматривались как дополнительный анализ, тогда как основная интерпретация латентной структуры основывалась на результатах классического факторного анализа.

Заключение

Проведенный многомерный анализ стандартных показателей иммунного статуса у клинически здоровых взрослых позволил выявить трехфакторную латентную структуру исследуемого иммунного профиля. Выбор трех факторов был согласованно подтвержден критерием Кайзера и параллельным анализом Хорна.

Выделенные факторы суммарно характеризовали 79,4% общей стандартизованной дисперсии анализируемых показателей.

Первый фактор характеризовал общий клеточный компонент периферической крови и объединял абсолютные количества основных клеточных популяций. Второй фактор отражал противопоставление нейтрофильно-гранулоцитарного и лимфоцитарного контуров и может рассматриваться как интегральная характеристика баланса врожденного и адаптивного клеточного иммунитета. Третий фактор характеризовался преимущественно положительными нагрузками моноцитов и эозинофилов при отрицательных нагрузках ряда лимфоцитарных и Т-клеточных показателей.

Дополнительное сопоставление результатов классического факторного анализа и Sparse PCA выявило частичное сходство структуры компонент; средняя абсолютная конгруэнтность Такера составила 0,772. В связи с этим основная интерпретация латентной структуры иммунного профиля основывалась на результатах классического факторного анализа, тогда как Sparse PCA использовался в качестве дополнительного метода многомерного анализа. Полученная трехфакторная структура позволяет перейти от анализа множества взаимосвязанных иммунологических показателей к ограниченному числу интегральных характеристик иммунного профиля. Выделенные латентные факторы могут использоваться в дальнейшем для исследования межиндивидуальной вариабельности иммунного статуса, сравнения здоровых обследуемых и пациентов с различными патологическими состояниями, а также для разработки многомерных подходов к интерпретации иммунограммы.

Исследование выполнено за счет гранта Российского научного фонда № 26-25-20053, <https://rscf.ru/project/26-25-20053/> и за счет целевого финансирования (гранта) Красноярского краевого фонда науки.

Список литературы

1. Brodin P., Davis M.M. Human immune system variation // Nature Reviews Immunology. 2017. Vol. 17. P. 21–29. DOI: 10.1038/nri.2016.125
2. Brodin P., Jojic V., Gao T. et al. Variation in the human immune system is

- largely driven by non-heritable influences // *Cell*. 2015. Vol. 160. No. 1–2. P. 37–47. DOI: 10.1016/j.cell.2014.12.020.
3. Carr E.J., Dooley J., Garcia-Perez J.E. et al. The cellular composition of the human immune system is shaped by age and cohabitation // *Nature Immunology*. 2016. Vol. 17. P. 461–468. DOI: 10.1038/ni.3371.
 4. Davis M.M., Tato C.M., Furman D. Systems immunology: just getting started // *Nature Immunology*. 2017. Vol. 18. P. 725–732. DOI: 10.1038/ni.3768.
 5. Fabrigar L.R., Wegener D.T., MacCallum R.C., Strahan E.J. Evaluating the use of exploratory factor analysis in psychological research // *Psychological Methods*. 1999. Vol. 4. No. 3. P. 272–299. DOI: 10.1037/1082-989X.4.3.272.
 6. van Buuren S., Groothuis-Oudshoorn K. mice: Multivariate Imputation by Chained Equations in R // *Journal of Statistical Software*. 2011. Vol. 45. No. 3. P. 1–67. DOI: 10.18637/jss.v045.i03.
 7. Kaiser H.F. A Second Generation Little Jiffy // *Psychometrika*. 1970. Vol. 35. No. 4. P. 401–415. DOI: 10.1007/BF02291817.
 8. Bartlett M.S. Tests of significance in factor analysis // *British Journal of Statistical Psychology*. 1950. Vol. 3. No. 2. P. 77–85. DOI: 10.1111/j.2044-8317.1950.tb00285.x.
 9. Kaiser H.F. The application of electronic computers to factor analysis // *Educational and Psychological Measurement*. 1960. Vol. 20. No. 1. P. 141–151. DOI: 10.1177/001316446002000116.
 10. Horn J.L. A rationale and test for the number of factors in factor analysis // *Psychometrika*. 1965. Vol. 30. No. 2. P. 179–185. DOI: 10.1007/BF02289447.
 11. Zou H., Hastie T., Tibshirani R. Sparse principal component analysis // *Journal of Computational and Graphical Statistics*. 2006. Vol. 15. No. 2. P. 265–286. DOI: 10.1198/106186006X113430.
 12. Lorenzo-Seva U., ten Berge J.M.F. Tucker's congruence coefficient as a meaningful index of factor similarity // *Methodology*. 2006. Vol. 2. No. 2. P. 57–64. DOI: 10.1027/1614-2241.2.2.57.

ОЦЕНКА ЗНАЧИМОСТИ ЛОКАЛЬНОЙ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ ДИКИХ ЖИВОТНЫХ ДЛЯ РАСПОЗНАВАНИЯ И ПОВТОРНОЙ ИДЕНТИФИКАЦИИ

Д.Н. Наталенко

Федеральное государственное бюджетное образовательное учреждение высшего образования «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева»

Введение. Автоматический анализ изображений диких животных является важным инструментом современного экологического мониторинга. Изображения, полученные с помощью фоторегистраторов, характеризуются значительным разнообразием ракурсов, масштабов и условий освещения, а животное может частично перекрываться растительностью или другими объектами природной сцены. Такие условия существенно усложняют как определение вида, так и повторную идентификацию отдельных особей.

Одним из подходов к повышению устойчивости распознавания и повторной идентификации является использование не только целостного представления животного, но и его локальных признаков. Part-based методы позволяют формировать представления на основе локальных областей и использовать доступную информацию при неполном наблюдении объекта. Подобные подходы уже применяются в задачах повторной идентификации, а современные методы используют специализированные Part-aware представления для повышения устойчивости к изменению ракурса и частичным перекрытиям [1-3].

Информативность локальных признаков может различаться для разных видов животных и решаемых задач, а при частичном перекрытии значение отдельных областей может изменяться. В связи с этим представляет интерес экспериментальное сравнение глобальной и локальной сегментации изображения, а также их комбинация в различных условиях наблюдения.

Постановка задачи. Рассмотрим изображение животного I , на котором могут быть выделены четыре пространственные области:

$$P = [P_s, P_b, P_h, P_f], \quad (1)$$

где P_s, P_b, P_h, P_f – отвечают за полную форму, туловище, голову и морду животного соответственно.

Для каждой области P_i формируется признаковое представление D_i . Для оценки информативности отдельных частей рассматриваются как индивидуальные представления D_i , где $i \in P$, так и их комбинации $D_S = \text{concat}(D_i | i \in S)$, где $S \subseteq P$.

Для каждой комбинации S определяется качество решения рассматриваемой задачи $M(S)$. Относительный вклад области P_i может быть оценен по изменению качества при ее добавлении или исключении, согласно формуле:

$$\Delta_i = M(P) - M(P \setminus P_i), \quad (2)$$

где $M(P)$ – качество при использовании всех исследуемых областей, а $M(P \setminus P_i)$ – качество при исключении области P_i .

Исследование проводится для двух задач: распознавании видов и повторной идентификации особей. В задаче распознавания определяется вид животного, тогда как в задаче повторной идентификации для изображения-запроса q необходимо найти соответствующую особь в галерее G , согласно выражению:

$$\hat{g} = \arg \max_{g \in G} \text{sim}(D_q, D_g), \quad (3)$$

где sim – мера сходства признаковых представлений

Дополнительно рассматриваются изображения с частично недоступными областями. Для каждой области вводится индикатор $m_i \in \{0,1\}$, определяющий ее наличие на изображении. Это позволяет исследовать не только абсолютную информативность локальных признаков, но и их устойчивость при неполном наблюдении животного.

Таким образом, задача исследования заключается в экспериментальном определении относительного вклада полной формы, туловища, головы и морды в распознавание вида и повторную идентификацию особи, а также в установлении зависимости этого вклада от вида животного, используемой модели и степени перекрытия объекта.

Методика исследования. Для исследования использовались изображения трех видов диких животных: медведя, волка и оленя, полученные в естественных природных условиях. Для каждого изображения формировались представления

четырёх исследуемых областей: полной формы, туловища, головы и морды. Такой набор областей выбран для сопоставления глобальных признаков животного с локальными признаками различного пространственного масштаба.

Для обеспечения сопоставимости результатов для всех моделей использовались одинаковые наборы изображений и единые условия формирования исследуемых областей. Для каждой области выполнялось отдельное извлечение признаков, после чего оценивалось качество распознавания при ее самостоятельном использовании. Полученные результаты сравнивались между видами животных и архитектурами моделей.

Тестирование выполнялось с использованием двух моделей классификации – ConvNeXt и ViT [4, 5]. ConvNeXt представляет современную сверточную архитектуру, тогда как ViT использует механизм самовнимания и последовательное представление изображения в виде набора патчей. Для повторной идентификации использовались OSNet и TransReID [6, 7], представляющие соответственно сверточный и Transformer-подходы к формированию признаков повторной идентификации. Выбор моделей обеспечивает сравнение информативности признаков независимо от конкретного типа архитектуры.

Для каждой модели проводилось абляционное исследование. Сравнивались представления, сформированные на основе каждой области отдельно, а также различные комбинации областей. Основным полным представлением считалась комбинация четырех частей:

$$D_{all} = D_s || D_b || D_h || D_f. \quad (4)$$

Для определения вклада каждой области сравнивалось качество полного представления с качеством представления без соответствующей части. Дополнительно анализировалось изменение результата при последовательном добавлении областей.

Наборы данных. Для определения информативности отдельных локальных признаков животных использовался набор реальных изображений, полученных с помощью фоторегистраторов, установленных на территории национального парка «Ергаки», а также открытые данные из сети Интернет. Изображения характеризуются различными условиями съемки, включая изменение освещения,

масштаба и ракурса животного, наличие растительности и других элементов природного окружения.

Исходные изображения дополнительно подвергались аугментации с имитацией перекрытия объекта элементами окружающей среды. В базовом варианте перекрытие формировалось путем наложения масок прямоугольной формы на изображение животного. Положение и размер маски выбирались таким образом, чтобы она полностью или частично перекрывала заданную область объекта. В отличие от случайного удаления пикселей, такой способ позволяет контролируемо задавать недоступность конкретной части животного и формировать наборы изображений с различными комбинациями доступных областей. Для каждого исходного изображения формировались варианты с различными состояниями доступности областей.

Содержание набора данных представлено в таблице 1.

Таблица 1

Содержание набора данных

Набор данных	Виды	Аугментации	Количество особей	Количество изображений
Распознавание	Медведь	Частичное перекрытие объекта при помощи маски	—	1226
	Косуля			1360
	Волк			1280
Повторная идентификация	Медведь	маски	20	300
	Косуля		23	345
	Волк		19	285

Примеры используемых изображений показаны на рисунке 1.



(а)

(б)

Рис.1. Примеры изображений: а) оригинальные изображения, б) аугментированные изображения

Такой подход к формированию набора данных обеспечил возможность непосредственного исследования зависимости качества распознавания от состава доступных частей объекта.

Экспериментальные результаты. Тестирование проводилось отдельно для видовой классификации и повторной идентификации. Для распознавания использовались Accuracy, Recall, Precision и F1-score, а для повторной идентификации – стандартные показатели Rank-1 и Rank-5. Сравнение выполнялось при одинаковых условиях обучения и тестирования, что позволяло связывать изменение качества непосредственно с составом доступных частей тела.

Результаты тестирования моделей видовой классификации представлено в таблице 2.

Таблица 2

Результаты тестирования моделей распознавания видов

Модель	Вид	Состав	Accuracy,	Recall,	Precision,	F1-score,
Con- vNeXt	Медвед ь	Форма	78,40	80,12	79,31	79,71
		Тело	74,90	76,48	77,26	76,86
		Голова	85,80	87,42	86,73	87,07
		Морда	91,70	92,86	91,45	92,15
		Все	95,60	96,18	95,42	95,80
	Олень	Форма	77,86	79,24	81,37	80,29
		Тело	74,63	75,81	78,46	77,11
		Голова	85,47	86,38	87,92	87,14
		Морда	91,38	92,17	92,84	92,50
		Все	95,34	95,76	96,21	95,98
	Волк	Форма	78,92	83,47	80,68	82,04
		Тело	75,18	78,34	76,29	77,30
		Голова	86,21	87,63	86,84	87,23
		Морда	92,14	94,02	92,31	93,15
		Все	96,08	96,72	95,86	96,29
ViT	Медвед ь	Форма	80,70	82,84	81,46	82,14
		Тело	76,80	78,61	79,84	79,22
		Голова	87,90	89,54	88,27	88,90
		Морда	93,10	94,21	93,36	93,78
		Все	96,80	97,34	96,71	97,02
	Олень	Форма	80,34	81,27	83,69	82,46
		Тело	76,51	77,82	80,16	78,97
		Голова	87,64	88,43	90,18	89,30
		Морда	92,86	93,41	94,73	94,06
		Все	96,54	96,92	97,28	97,10
	Волк	Форма	81,12	85,76	83,84	84,79
		Тело	77,24	80,52	78,67	79,58
		Голова	88,32	89,41	88,76	89,08
		Морда	93,47	95,18	94,21	94,69
		Все	97,02	97,86	96,94	97,40

Результаты тестирования моделей повторной идентификации представлено в таблице 3.

Таблица 3

Результаты тестирования моделей повторной идентификации

Модель	Вид	Состав	Rank-1, %	Rank-5, %
OSNet	Мед- ведь	Форма	61,24	69,18
		Тело	57,63	64,47
		Голова	72,35	78,62
		Морда	82,41	88,73
		Все ча-	88,26	93,84

	Олень	Форма	57,18	64,92
		Тело	54,63	61,47
		Голова	69,35	76,28
		Морда	80,42	87,16
OSNet	Олень	Все ча-	88,26	93,84
		Форма	63,27	70,84
	Волк	Тело	59,41	66,53
		Голова	74,28	81,35
		Морда	84,36	90,72
		Все	90,24	95,18
TransRel D	Мед- ведь	Форма	66,31	73,86
		Тело	62,47	69,24
		Голова	78,36	84,71
		Морда	87,28	92,64
		Все	92,43	97,18
	Олень	Форма	62,18	69,73
		Тело	59,36	66,42
		Голова	75,27	82,64
		Морда	85,34	91,58
		Все	90,47	96,12
	Волк	Форма	68,24	75,86
		Тело	64,38	71,27
		Голова	80,43	87,35
		Морда	89,27	94,63
		Все	93,41	98,16

Результаты проведенного тестирования показывают, что вклад отдельных локальных признаков зависит от решаемой задачи и архитектуры модели. Для обеих моделей распознавания среди отдельных областей наиболее высокие показатели в среднем обеспечивала морда, за ней следовала голова. Полная форма и туловище демонстрировали более близкие и, как правило, меньшие значения. Использование всех четырех областей обеспечивало максимальное качество для всех трех видов, что указывает на взаимодополняемость глобальных и локальных признаков.

В задаче повторной идентификации наблюдалась аналогичная общая тенденция, причем различия между отдельными областями были выражены сильнее. Наибольшие значения Rank-1 и Rank-5 получены при использовании признаков морды, несколько меньшие – головы. Полная форма и туловище обеспечивали более низкие результаты, однако их включение в состав полного представления приводило к дополнительному приросту качества. Тенденция сохранялась для обеих

моделей, при этом TransReID демонстрировал более высокие абсолютные показатели, чем OSNet.

Сравнение трех видов показывает, что последовательность информативности в целом сохраняется, но ее выраженность зависит от вида. Для медведя и волка преимущество локальных признаков головы и морды над полной формой и туловищем выражено сильнее, а для оленя различия между головой и мордой несколько меньше. Таким образом, результаты указывают на общую тенденцию «морда-голова-форма/тело», но не позволяют считать ее полностью независимой от вида и используемой архитектуры.

Заключение. В работе экспериментально исследована относительная информативность четырех пространственных локальных сегментов изображений с дикими животными для задач распознавания вида и повторной идентификации: полной формы, туловища, головы и морды. Исследование проведено на изображениях медведя, волка и оленя с использованием двух моделей распознавания и двух моделей повторной идентификации.

Абляционный анализ показал, что локальные области головы и морды в среднем обеспечивают больший вклад в качество распознавания, чем полная форма и туловище. Наиболее устойчиво высокий результат демонстрировала область морды, однако ее преимущество зависело от вида и модели. Совместное использование всех четырех областей во всех рассмотренных случаях повышало качество относительно отдельных представлений, что подтверждает наличие взаимодополняющей информации.

Для повторной идентификации выявлена аналогичная последовательность информативности, при этом преимущество локальных признаков выражено сильнее. Полученные результаты показывают, что при построении Part-based систем целесообразно учитывать неодинаковую информативность различных признаков, а также используемую архитектуру и условия наблюдения.

Дополнительное моделирование частичных перекрытий позволяет рассматривать полученные закономерности с точки зрения устойчивости к неполному наблюдению. Перспективным направлением дальнейшей работы является количественное определение оптимальных весов частей на основе их среднего

вклада и исследование более реалистичных форм перекрытия, соответствующих растительности и другим объектам природной сцены.

Список литературы

1. Automatic identification of individual yaks in in-the-wild images using part-based convolutional networks with self-supervised learning / S. Li, J. Li, H. Tang [et. al.] // Expert Systems with Applications, Vol. 216. – 2023. – Art. No. 119431.
2. Addressing the Elephant in the Room: Robust Animal Re-Identification with Un-supervised Part-Based Feature Alignment / Y. Yu, V. Vidit, A. Davydov [et. al.] // Proceedings of the CVPR Workshop on Computer Vision for Animal Behavior (CV4Animals). – 2024. – arXiv ID: 2405.13781.
3. An improved architecture for part-based animal re-identification through semantic segmentation distillation / E. D. R. Neto, M. Chaumont, G. Subsol [et. al.] // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. – 2026. – Art. No. 10.1109/WACV61042.2026.00512.
4. A ConvNet for the 2020s / Z. Liu, H. Mao, C.-Y. Wu [et al.] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. – 2022. – P. 11966-11976.
5. An Image Is Worth 16x16 Words: Transformers for Image Recognition at Scale / A. Dosovitskiy, L. Beyer, A. Kolesnikov [et al.] // International Conference on Learning Representations. – 2021. – arXiv ID: 2010.11929.
6. Omni-Scale Feature Learning for Person Re-Identification / K. Zhou, Y. Yang, A. Cavallaro [et al.] // Proceedings of the IEEE/CVF International Conference on Computer Vision. – 2019. – P. 3765-3773.
7. TransReID: Transformer-Based Object Re-Identification / S. He, H. Luo, P. Wang [et al.] // Proceedings of the IEEE/CVF International Conference on Computer Vision. – 2021. – P.14993-15002.

К ВОПРОСУ ИЗУЧЕНИЯ ГОРНЫХ ЛЕСОВ ²

Н.Ф. Овчинникова¹, А.Г. Тутынин²

¹Институт леса им. В.Н.Сукачева СО РАН, Федеральный исследовательский центр «Красноярский научный центр СО РАН», nf@ksc.krasn.ru

² ООО «ФОРЕСТ ОС», sibkub@yandex.ru


Создание сети постоянных пробных площадей (ППП) с последующим проведением на них длительных комплексных исследований – хорошо известный и надежный метод наблюдений, позволяющий получить разностороннюю достоверную информацию о состоянии лесных экосистем на разных этапах их роста и развития. Систематические измерения таксационных признаков деревьев позволяют фиксировать происходящие изменения в составе, структуре, состоянии и продуктивности древостоев. Однако проследить такие изменения на большом интервале времени весьма проблематично из-за быстрой утраты данных и объектов изучения.

К отобраным под ППП насаждениям предъявляются строгие требования: они должны быть однородны по происхождению, составу, возрасту, густоте, типу леса, классу бонитета и т.д. [7]. Если в равнинных лесах подбор участков под ППП, отвечающим данным условиям, обычно не вызывает сложностей, то в горных лесах он практически невозможен. Горный рельеф, являющийся наиболее стабильным компонентом лесных ландшафтов, играет огромную роль в перераспределении в пространстве таких основных экологических факторов, как температура и влажность приземного слоя воздуха и почвы, а также количества солнечной радиации, поступающей на единицу поверхности [5]. Неравномерность распределения солнечной радиации на склонах различной экспозиции и крутизны наиболее четко проявляется на длительности безморозного периода и интенсивности заморозков, особенно при наличии склоновых ветров. В теплое время года

¹ В рамках Базового проекта «Роль природных и антропогенных факторов в системе устойчивого управления лесами Сибири (2024-2026 гг.)», №FWES-2024-0007, Рег.НИОКТР №124012900559-4

из-за воды, поступающей с вышележащих участков, влагозапасы в почве в различных частях склона не одинаковы на относительно небольших расстояниях [16].

Наши наблюдения на ППП, заложенных в лиственных и светлохвойных одновозрастных древостоях на склонах Западного и Восточного Саян, показали, что неоднородность экологических условий, имеющих место на 30-40-метровых



отрезках пологого склона (до 10 градусов), сказывается в первую очередь на интенсивности самоизреживания древостоя [11, 13]. Неравномерный отпад деревьев, приводит к перестройке горизонтальной структуры древостоя и формированию клинального размещения деревьев на склоне, как показано на рисунке.

Рис. Схема размещения деревьев и разметки на ППП: 1 – деревья, растущие в 2012 г.; 2 – отпад в 1968–2012 гг.; 3 – опорные точки; 4 – границы участка площадью 0,2 га [11].

Выделение таксационных выделов при лесоустройстве горных лесов производят по тем же таксационным признакам, как и в равнинных лесах, но с учетом экспозиции, крутизны склонов и высоты над уровнем моря. Если отдельные части склона отличаются по крутизне более чем на 10 градусов, то они должны относиться к разным выделам. Для определения числа измеряемых деревьев на ППП существуют придержки: в молодняках, должно быть не менее 400 деревьев, в приспевающих и средневозрастных – не менее 300, в спелых – не менее 200, в перестойных – не менее 150 деревьев главной породы.

С целью получения статистически достоверных результатов используется общепринятая в биологических исследованиях формула:

$$n = \frac{t^2 \times V^2}{p^2},$$

где n – необходимое число измеряемых деревьев основного элемента леса, шт.;

V – коэффициент изменчивости признака, %;

p – заданная точность опыта, %;

t – коэффициент достоверности выводов (при $t_{0.68}=1$, при $t_{0.95}=2$, при $t_{0.99}=3$).

В условиях современной климатической нестабильности, когда месячная норма летних осадков выпадает в течение нескольких часов, повышается роль изучения горных лесов, обеспечивающих нормальный ход гидрологических процессов, устойчивость почвенного покрова и всех компонентов горного ландшафта [2, 3]. В этой связи в первую очередь необходимо выяснить насколько методики исследований лесных экосистем, получившие широкое применение в равнинных лесах, соответствуют природе горных лесов, а именно, какой должна быть форма ППП и особенности их размещения на склоне, чтобы учесть особенности горного рельефа и его влияния на лесную растительность. Пробные площади могут различаться по форме: четырехугольные, ленточные и круговые.

В 2020 г. в России был завершен первый цикл государственной инвентаризации лесов (ГИЛ) в масштабе страны новым видом лесоучетных работ, представленный тремя круговыми учетными площадками с общим центром. Размер этих площадок 25, 100 и 500 кв.м. Целью данной инвентаризации лесов является не оценка традиционных переменных, характеризующих леса (породный состав, запас древесины, возраст и др.), а мониторинг происходящих в лесу изменений и их направленности [8]. В Приказе Минприроды РФ от 27.09.2021 поясняется, что форма каждой ППП представляет круг площадью 0,05 га [17].

Геометрический расчет показывает, что если ППП в форме круга разделить горизонталями на три равные по площади секции, то протяженность верхней и нижней секции по склону будет больше центральной. Возникающая системная ошибка в определении густоты древостоя при клинальном размещении деревьев по склону не может быть исправлена увеличением диаметров ППП, или их численностью. Отсюда следует вывод, что в горных лесах круговые ППП будут давать неточные таксационные показатели.

Пробные площади обычной прямоугольной формы для лучшего ориентирования и привязки местоположения деревьев в плоскостных координатах (X и Y) разделяются визирами на квадраты размером 5х5 или 10х10 кв.м. Для построения цифровой модели местности ППП у каждого угла квадрата должна быть определена третья координата - условная или абсолютная высота над уровнем моря [10].

Большинство сведений о динамике лесов получено косвенным методом «временных рядов», т.е. сравнительного изучения растительных сообществ, составляющих пространственные сукцессионные ряды. Само предположение, что изучение изменений во времени можно заменить исследованием изменений сообществ в пространстве, вносит субъективизм еще на стадии сбора материала. Ведущиеся с середины XVIII в. исследования динамики древостоев, привели к противоречивым выводам о общих закономерностях. Хотя постоянно создаются методы изучения многолетней динамики в наиболее короткие сроки и имеются оригинальные количественные методы прогноза процессов роста отдельных видов и популяций растений, но для совокупности лесных популяций, многовидовых и разновозрастных сообществ, существуют лишь словесные описания динамических процессов [6].

Одна из существующих гипотез – становление пространственно-возрастной структуры древесных ценозов в рамках онтоценогенеза в ценоячейках, где развитие особей синхронизировано [1]. Однако объем пространства, площадь синхронизации, соизмерим с расстоянием, на котором сказывается влияние одной особи на другую. Когда пространство превышает радиус индивидуального влияния, причины, синхронизирующие фазы динамики удаленных друг от друга особей, могут лежать только вне сообщества. Необходимо доказать, каким образом особи ценопопуляции оказываются взаимосвязанными за пределами осязаемости их взаимодействий. Сложность заключается в том, что приспособляясь к условиям роста, деревья, соответственно генотипическим особенностям, размерам и

состоянию, вырабатывают специфический тип роста, от которого зависит их внутривидовая изменчивость и дифференциация, в результате которой в каждом древесном ценозе формируется свое размещение особей на площади.

Нагимов З.Я., изучив закономерности роста и формирования наземной массы сосновых древостоев, установил, что варьирование густоты в той или иной мере оказывает влияние на все параметры деревьев в насаждении, в том числе и на наиболее крупные. С возрастом изменение диаметра деревьев происходит не пропорционально изменениям густоты произрастания деревьев, а с некоторым отставанием, что сохраняется до возраста спелости древостоя [9].

В основе нашей работы лежит наиболее длительный и подробный ряд наземных наблюдений за растительным покровом, полученный на ППП в Сибири. В 60-70-х годах XX в. ППП закладывались в различных лесорастительных условиях в древостоях разного видового состава, возраста. Согласно принятой методике [4], на ППП сделана съемка микрорельефа и вся древесная растительность картировалась при проведении сплошных учетов. Данные хранятся в виде электронных таблиц пакета Microsoft Excel. На сегодняшний день в зарегистрированной Базе данных [12] более 30 тыс. записей. Каждая запись содержит в нескольких временных срезах информацию о параметрах и состоянии каждого закартированного на 14 ППП древесного растения. ППП расположены на разной высоте над уровнем моря в двух районах Красноярского края. Наибольший ряд наблюдений с 1968 по 2012 гг.

Большой объем оригинальных наземных данных позволил не только использовать классические и общепринятые методы их анализа, но и в начале 2000-х начать применять нейронные сети для изучения лесных сукцессий [14]. Предполагалось, что использование нейронной сети даст возможность устранить наиболее сложную часть - формализацию задачи и строить математическое представление путем "обучения" нейросети по экспериментальным данным. Такой подход должен был позволить ускорить и упростить этот этап исследований.

Разрабатываемые Красноярской школой нейросетевые экспертные системы планировалось использовать для:

прогноза жизнеспособности особи (подроста, дерева) по его таксационным характеристикам, таким как высота, диаметр ствола; ширина и протяженность кроны; расстояние от основания ствола до кроны (очищение ствола) и др.;

определения зависимости хода роста деревьев разных пород от окружающей среды; климатических, почвенных условий;

выявления влияния на ход роста растения или элемента леса, породы, фитоценотического окружения (конкурентных взаимоотношений с другими растениями. породами);

определения связи ценотической роли отдельных деревьев (пород) с возрастом насаждения;

вычисление значимости входных данных (используемых признаков, характеристик) для получения перечисленных экспертных оценок.

Последнюю задачу получилось частично решить [15]. Определение значимости входных данных позволило пересмотреть уровень значимости отдельных характеристик для извлечения экспертных знаний. Для ее решения была представлена База данных характеристик, измеренных с периодичностью в 4-7 лет параметров деревьев в Западном Саяне, в 1976-2008 гг. Для каждого дерева были представлены параметры ствола, кроны и расчетные, например, площадь питания. База содержит сведения о четырех породах деревьев. В качестве начальной обучающей выборки для нейросетей были выбраны данные по осине, поскольку для этой породы деревья были представлены одним возрастом и в достаточном количестве.

Были выделены 11 измеренных параметров и характеристик 677 деревьев. В них входили: диаметр ствола на высоте 1.3 метра, высота дерева, расстояние от земли до кроны, диаметр кроны, высота кроны, площадь кроны (у основания), объем кроны, площадь ствола на высоте 1.3 метра, объем ствола, класс роста при первом измерении, класс роста при втором измерении. При определении значащих входных параметров из 11 исходных признаков было выделено 3 параметра: диаметр ствола на высоте 1.3 метра, высота дерева, расстояние от земли до кроны.

В настоящее время работа с этими данными планируется продолжить.

Нейронные сети или Искусственный интеллект (ИИ) может использовать материалы наземного мониторинга для решения разных групп задач:

- прослеживать изменение состояния каждого дерева между последовательными учётами;
- выявлять пропуски, ошибки измерений и несогласованности в исходных таблицах;
- рассчитывать индивидуальный прирост диаметра и высоты;
- оценивать вероятность гибели дерева в следующем интервале наблюдений;
- исследовать влияние породы, размеров дерева, параметров кроны и класса роста;
- анализировать пространственную конкуренцию и влияние ближайших соседей;
- изучать изменение породной и размерной структуры древостоя;
- формировать проверяемые гипотезы о ходе лесовосстановительной сукцессии;
- оценивать достоверность получаемых прогнозов и показывать границы их применимости.

При таком подходе ИИ не заменяет исследователя и не формулирует окончательные выводы автоматически. Его задача — систематизировать большой объём наблюдений, находить статистические закономерности, проверять гипотезы и явно отделять измеренный факт от расчёта, предположения или причинной интерпретации.

Список литературы

1. Анализ структуры древесных ценозов / А.И. Бузыкин [и др.]. – Новосибирск: Наука.Сиб. отд-ние, – 1985. – 95 с.
2. Буренина, Т.А. Изменение структуры водного баланса на вырубках черневого пояса Западного Саяна / Т.А. Буренина, Н.Ф. Овчинникова, Е.В. Федотова // География и природные ресурсы. – 2011. – № 1. – С. 92-100.

3. Буренина, Т.А., Изменение структуры влагооборота в связи с возрастной и восстановительной динамикой лесных экосистем / Т.А. Буренина, Е.В. Федотова, Н.Ф. Овчинникова // Сибирский экологический журнал – 2012, № 3, С. 435-445.
4. Ермоленко, П.М. Пространственно-временная структура древостоев темнохвойных лесов Западного Саяна / П.М.Ермоленко // В: Продуктивность и структура лесных сообществ. – Красноярск: ИЛиД, – 1985. – С. 59-70.
5. Костюкевич, Н.И. Лесная метеорология / Н.И. Костюкевич. – Минск: Высшая школа, – 1975. – 288 с.
6. Кузьмичев, В.В. Закономерности динамики древостоев / В.В.Кузьмичев. – Новосибирск: Наука, – 2013. – 208 с.
7. Лежнев, Д.В. Методологические основы комплексных исследований лесных фитоценозов / Д.В. Лежнев // Экологический мониторинг и моделирование экосистем, т. XXXVI, № 3-4, – 2025, – с. 19-56.
8. Малышева, Н.В. Анализ зарубежного опыта национальных инвентаризаций лесов, методы выборки, результаты и международная статистика / Н.В. Малышева, А.Н. Филипчук, Т.А. Золина, П.С. Кинигопуло, Е.М. Шалимова, С.А. Попов, Г.В. Сильнягина Г.В. // Лесохозяйственная информация, – 2022, №2. – с.90-132.
9. Нагимов, З.Я. Закономерности роста и формирования наземной фитомассы сосновых древостоев / З.Я. Нагимов // Автореф. дис. докт. с/х наук, Екатеринбург, – 2000. – 24 с.
10. Овчинникова, Н.Ф. Изучение влияния рельефа на динамику пространственной структуры и рост древостоев / Н.Ф. Овчинникова // Моделирование неравновесных систем: Материалы XXII Всероссийского семинара, / Под ред. М.Г. Садовского; отв. за вып. М.Ю.Сенашева; – Красноярск: Институт вычислительного моделирования Сибирского отделения РАН, – 2019. – С. 73-78.
11. Овчинникова, Н.Ф. Особенности пространственно-временной структуры соснового древостоя на южном склоне Восточного Саяна / Н.Ф. Овчинникова // Изв. вузов. Лесн. журн. – 2021. №5. – С.34-47.

12. Овчинникова, Н.Ф. Учеты деревьев на постоянных пробных площадях Красноярского края / Н.Ф.Овчинникова, А.Е.Овчинников // Свидетельство о государственной регистрации базы данных №2011620706, заявл. 05.08.2011, зарег. 30.09.2011.
13. Овчинникова, Н.Ф. Динамика структуры осинового древостоя в черневом поясе Западного Саяна / Н.Ф.Овчинникова, А.Е.Овчинников // Лесоведение. – 2016, – №6. – С. 418-425.
14. Овчинникова Н.Ф. Перспективы изучения лесных сукцессий с использованием нейросетевых экспертных систем / Н.Ф. Овчинникова, Ю.П. Ланкин // II Всероссийская конференция "Нейрокомпьютеры и их применение" с международным участием "НКП-2001".– М.: ИПРЖР, – 2001. – С. 351-355.
15. Овчинникова Н.Ф. Изучение лесных сукцессий при помощи нейронных сетей / Н.Ф. Овчинникова, М.Г. Садовский, М.Ю. Сенашова, И.С. Хорев // Нейроинформатика, ее приложения и анализ данных: Материалы XV Всероссийского семинара, 5-7 октября 2007 г. / Под ред. А.Н. Горбаня, Е.М. Миркеса. Отв. За выпуск Г.М. Садовская, ИВМ СО РАН, – Красноярск, 2007. – С. 94-98.
16. Пикин, С.Ф. Гравитационная кинематическая модель рельефа / С.Ф. Пикин // Ставрополь, изд-во: СГУ, – 2005, – 380 с.
17. Приказ Минприроды РФ от 27.09.2021 №686. II. Оценка состояния лесов, их количественных и качественных характеристик. <https://normativ.kontur.ru/document?moduleId=1&documentId=411612>, дата обращения 04.09.2026.

КРИТЕРИИ ВЫБОРА МОДЕЛИ СЕГМЕНТАЦИИ ЗАМАСКИРОВАННЫХ ОБЪЕКТОВ ЖИВОЙ ПРИРОДЫ НА ИЗОБРАЖЕНИЯХ

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. Сегментация замаскированных объектов (Camouflaged Object Segmentation, COS) живой природы на изображениях является одной из наиболее сложных задач компьютерного зрения, поскольку объект интереса и окружающий фон обладают высокой степенью сходства по цвету, текстуре и яркости. Изначально для решения задачи сегментации таких объектов применялись традиционные методы обработки изображений, основанные на анализе яркости, контраста, глобальных текстурных характеристик и других низкоуровневых признаков [1, 2]. Однако высокая визуальная схожесть замаскированного объекта с окружающим фоном существенно ограничила эффективность таких подходов. Полученные предсказательные бинарные маски обладали высокой степенью фрагментарности, а также нечёткостью границ, что приводило к потере отдельных частей объекта, а иногда, наоборот, к добавлению лишних фоновых областей в маску сегментации. Дальнейшее развитие задачи COS было связано с применением методов глубокого обучения, способных формировать более сложные представления визуальных признаков и учитывать как пространственный, так и структурный контекст изображения.

Использование только одного фиксированного метода для всех входных изображений не позволяет учитывать существенное разнообразие условий, возникающих при сегментации замаскированных объектов. Следовательно, метод, обеспечивающий наиболее точную сегментацию для одного типа изображения, не обязательно будет оптимальным для другого типа сцены. Целью настоящей работы является формирование критериев выбора модели сегментации в зависимости от локальных структурных характеристик входного изображения.

Критерии выбора моделей сегментации. Для формирования критериев выбора модели необходимо предварительно определить основные типы сцен для изображений в задаче COS. В ходе работы были выделены три характерных типа сцен.

К первому типу относятся изображения, на которых замаскированный объект имеет достаточно выраженные пространственные границы и устойчивую текстуру. Переход между объектом и фоном в таких изображениях сопровождается заметным изменением яркости. Для данного типа сцен существенную информацию об объекте содержат пространственные градиенты и контуры объекта. Ко второму типу относятся изображения с размытыми или слабо выраженными границами объекта. В таких сценах локальные контуры могут быть недостаточно информативными, а текстурные компоненты нечёткими. В результате стандартное выделение границ становится менее надёжным, а качество сегментации в большей степени зависит от способности модели восстанавливать пространственную структуру объекта. Третий тип представлен изображениями, на которых объект имеет низкий контраст относительно окружающего фона. В данном случае объект и фон могут обладать близкими значениями яркости и текстуры. Для сегментации таких изображений основной проблемой становится не столько размытость границы, сколько недостаточная различимость объекта и фона.

На основании выявленных закономерностей различных типов сцен был сформирован набор критериев, характеризующих структурные свойства исходного изображения. Критерии должны вычисляться только для входного изображения I и не требовать наличия эталонной маски. Для оценки выраженности пространственных градиентов был выбран оператор Собеля, позволяющий характеризовать интенсивность изменения яркости в горизонтальном и вертикальном направлениях. Определялась его нормированная средняя величина:

$$S(I) = \frac{1}{N} \sum_{i=1}^N \frac{\sqrt{G_x^2(i) + G_y^2(i)}}{G_{\max}},$$

где G_x и G_y – горизонтальная и вертикальная компоненты оператора Собеля, N – количество пикселей изображения, $G_{\max}$ – максимальное значение градиента для нормализации в пределах от 0 до 1.

Для анализа изображений с размытыми границами используется дисперсия Лапласиана. В отличие от оператора Собеля, характеризующего преимущественно величину градиента, дисперсия Лапласиана позволяет оценить наличие мелкомасштабных структур и резких пространственных переходов в изображении. Данный показатель широко используется как количественная характеристика резкости изображения: при наличии чётких границ значение данного показателя увеличивается, тогда как при размытии текстуры изображения оно уменьшается. Дисперсию Лапласиана можно представить в следующем виде:

$$L(I) = D(\nabla^2 I),$$

где ∇^2 – оператор Лапласа, D – дисперсия, а $L(I)$ характеризует степень пространственной неоднородности для исходного изображения.

Для оценки различимости объекта и окружающего фона выбран показатель локальной контрастности, получаемый на основе анализа гистограммы CLAHE (Contrast Limited Adaptive Histogram Equalization). В отличие от глобальной оценки контраста, CLAHE выполняет обработку небольших локальных областей изображения, ограничивая коэффициент усиления контраста. Коэффициент локальной контрастности изображения может быть представлен в виде:

$$LC_{CLAHE}(I) = \frac{1}{N} \sum_{i=1}^N |I_{CLAHE}(i) - I|,$$

где N – количество пикселей изображения, I_{CLAHE} – гистограмма изображения, LC_{CLAHE} – оператор локальной контрастности, полученный после анализа гистограммы. Чем меньше оператор LC_{CLAHE} , тем меньше контрастность между фоном и объектом.

Экспериментальная часть. Целью проведения экспериментов является определение критериев выбора для моделей сегментации замаскированных объектов живой природы в зависимости от характеристик сцены исходного изображения. Были взяты изображения из общедоступных наборов данных CAMO [4], COD-10K [5], NC4K [6], специально предназначенных для решения задачи COS. Всего было рассмотрено 200 изображений из набора данных CAMO, 250 изображений из набора данных COD-10K и 300 изображений из набора данных NC4K.

В ходе эксперимента исходные изображения подавались на три различные

модели сегментации замаскированных объектов. Модель SFSR-CODnet переводит исходное изображение из цветового пространства RGB в YUV с целью уменьшения числа обрабатываемых каналов. Затем модель анализирует яркостную компоненту исходного изображения и увеличивает его разрешение в 4 раза с использованием сети ESRGAN. Полученное изображение подвергается прямому дискретному вейвлет-преобразованию до 3 уровня, после чего над высокочастотной компонентой HH_3 производится морфологическая обработка, а низкочастотная компонента LL_3 подвергается локальному контрастированию. Затем модель выполняет обратное вейвлет-преобразование и уменьшает разрешение изображения до первоначального значения.

Пространственно-частотная модель SF-CODnet содержит в своей архитектуре систему из двух генераторов и трёх дискриминаторов. Пространственный генератор обрабатывает исходное «сильное» изображение и извлекает признаки, характеризующие положение и структуру потенциального замаскированного объекта. Частотный генератор параллельно обрабатывает несколько «слабых» примеров, в которых к случайному фрагменту контура применяется гауссово размытие, а также изменяются текстурные характеристики маски объекта. Дискриминаторы анализируют целостность полученной маски и оценивают её соответствие эталонной маске, заставляя генераторы более точно восстанавливать структуру объектов интереса.

Диффузионная модель UADP-COSnet осуществляет сегментацию исходного изображения посредством последовательного формирования маски объекта. Сначала исходное изображение подаётся на предварительно обученную сеть сегментации, параметры которой фиксируются и не изменяются в процессе обучения. Полученный результат используется для создания грубой бинарной маски, характеризующей предварительное положение замаскированного объекта. Далее формируется бинарная карта неопределённости, полученная путём сравнения пикселей эталонной и грубой масок. Затем грубая маска и карта неопределённости суммируются, после чего к полученной маске применяются прямой и обратный процессы диффузии.

Полученные моделями бинарные маски анализировались с точки зрения полноты выделения замаскированного объекта, его целостности и чёткости сформированных границ, после чего результаты сопоставлялись с визуальными и структурными характеристиками соответствующих исходных изображений. Проведённый анализ позволил выявить определённые закономерности между характером исходного изображения и качеством формируемой каждой моделью бинарной маски. На Рис.1 представлены некоторые примеры предсказательных бинарных масок, полученных для изображений с чёткими границами объектов и устойчивой текстурой.




Рис.1. Бинарные маски для изображений с выраженными границами и текстурой, полученные моделями: А) исходные изображения, Б) эталонные маски, В) маски SFSR-CODnet, Г) маски SF-CODnet, Д) маски UADP-COSnet.

На Рис.2 представлены предсказательные бинарные маски для изображений с размытой текстурой объекта.




Рис.2. Бинарные маски для изображений с размытой текстурой объекта, полученные моделями: А) исходные изображения, Б) эталонные маски, В) маски SFSR-CODnet, Г) маски SF-CODnet, Д) маски UADP-COSnet.

Рис.3 демонстрирует бинарные маски для изображений с низким контрастом объекта относительно фона.




Рис.3. Бинарные маски для изображений с низким контрастом, полученные моделями: А) исходные изображения, Б) эталонные маски, В) маски SFSR-CODnet, Г) маски SF-CODnet, Д) маски UADP-COSnet.

В ходе проведения эксперимента установлено, что сегментация изображений с более выраженными пространственными границами и относительно однородной текстурой, где значение оператора Собеля $s(I) > 0,72$ демонстрирует лучшие результаты для модели SFSR-CODnet. Также замечено, что для изображений с чёткими границами и устойчивыми текстурами значение дисперсии Лапласиана находилось в пределах $1200 < L(I) < 2900$, а для изображений с нечёткими границами и размытой текстурой в пределах $340 < L(I) < 900$. Модель SF-CODnet оказалась наиболее эффективной при наличии размытых и слабо выраженных границ объекта и даёт устойчивые результаты сегментации при значении $L(I) < 624$ практически на всех изображениях из тестовой выборки. Был проведён анализ гистограммы CLAHE и оценена локальная контрастность изображения. Установлено, что модель UADP-COSnet целесообразно применять в случаях, когда объект характеризуется низким контрастом относительно однородного окружающего фона. При значении $LC_{CLAHE} < 0,082$ модель UADP-COSnet формирует более лучшую маску сегментации, в сравнении с другими моделями.

Заключение. В данной работе были рассмотрены изображения с замаскированными объектами живой природы и выделены характерные типы сцен в зависимости от их структурных и визуальных характеристик. Анализ изображений позволил определить основные признаки, характеризующие выраженность границ объекта, степень резкости и локальную контрастность сцены. Сопоставление выделенных типов сцен с результатами сегментации, полученными различными моделями, позволило выявить устойчивые закономерности, связывающие характеристики исходного изображения с эффективностью применения рассматриваемых моделей.

Далее были выбраны критерии и определены их пороговые значения, которые рассматривались как эмпирические параметры и определялись экспериментально на тестовой выборке. Таким образом, предложенные критерии не предполагают универсальной зависимости между отдельным статистическим признаком и наличием замаскированного объекта, а используются как средство предварительного определения структурного типа изображения и выбора наиболее подходящей модели сегментации. Полученные результаты могут служить основой для

дальнейшего исследования моделей в задаче сегментации замаскированных объектов живой природы.

Список литературы

1. Liu Y., Zhang M., Fan Q., et al. Integrating part-object relationship and contrast for camouflaged object detection // IEEE Transactions on Information Forensics and Security. — 2021. — Vol. 16. — P. 5154–5166. — DOI: 10.1109/TIFS.2021.3119567.
2. Yang Y., Zhang Q. Finding camouflaged objects along the camouflage mechanisms // IEEE Transactions on Circuits and Systems for Video Technology. — 2023. — Vol. 34, No. 4. — P. 2346–2360. — DOI: 10.1109/TCSVT.2023.3308964.
3. Favorskaya M. N., Saidov N. V. SF-CODnet: Spatial-frequency framework with weak sample learning strategy for detecting camouflaged wildlife objects // The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. — 2025. — Vol. XLVIII-2/W9. — P. 79–86. — DOI: 10.5194/isprs-archives-XLVIII-2-W9-2025-79-2025.
4. Le T.-N., Nguyen T. V., Nie Z., et al. Anabranh network for camouflaged object segmentation // Computer Vision and Image Understanding. — 2019. — Vol. 184. — P. 45–56. — DOI: 10.1016/j.cviu.2019.04.006.
5. Fan D.-P., Ji G.-P., Cheng M.-M., et al. Concealed object detection // IEEE Transactions on Pattern Analysis and Machine Intelligence. — 2022. — Vol. 44, No. 10. — P. 6024–6042. — DOI: 10.1109/TPAMI.2021.3085766.
6. Lv Y., Zhang J., Dai Y., et al. Simultaneously localize, segment and rank the camouflaged objects // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. — 2021. — P. 11591–11601. — DOI: 10.1109/CVPR46437.2021.01142.

ВЛИЯНИЕ ТЕМПЕРАТУРНЫХ ИНВЕРСИЙ НА УРОВЕНЬ ЗАГРЯЗНЕНИЯ ПРИЗЕМНОГО СЛОЯ АТМОСФЕРЫ В КРАСНОЯРСКЕ В ЗИМНИЙ ПЕРИОД

М.Ю. Сенашова

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

Введение. Загрязнение атмосферного воздуха в крупных городах является многогранной проблемой. Загрязнения влияют как на заболеваемость населения, так и в целом на экологическую обстановку в городах. Этой проблеме посвящено много работ в России и за рубежом [1-6].

В работе мы анализируем влияние температурной инверсии на уровень загрязнений воздуха в г. Красноярске. Источниками загрязнений являются автотранспорт, промышленные предприятия и печное отопление в зимний период. Данные о загрязнениях получены с постов наблюдения, расположенных в г. Красноярске. Посты наблюдения расположены в следующих местах г. Красноярска: Ветлужанка, Кировский, Покровка, Северный, Солнечный, Свердловский, Черемушки и г. Сосновоборск. На каждом посту наблюдения собираются следующие данные о погодных условиях и загрязнении воздуха: температура воздуха (t), влажность (h), давление (p), сила и направление ветра (wv и wd), количество взвешенных частиц (pm), уровень диоксида азота (NO_2), монооксида азота (NO), аммиака (NH_3), сероводорода (H_2S), диоксида серы (SO_2) и угарного газа (CO). Данные на постах фиксируются каждые 20 минут и затем агрегируются в данные за час и в данные за день. Данные о температурной инверсии получены с профиломера, находящегося в районе р. Кача. Данные на профиломере фиксируются каждые 5 минут. Мы используем рассчитанную для часового интервала интенсивность инверсии t_delta , нижний и верхний уровень h_min и h_max . Мы используем часовые данные, поскольку это позволяет избежать как излишней детализации, так и излишнего обобщения. В своей работе мы будем рассматривать строку данных как точку в 15-мерном пространстве. Для визуализации и сокращения размерности данных мы используем свободно распространяемую программу VidaExpert (<https://www.ihes.fr/~zinovyev/vida/vidaexpert.htm>). Эта программа работает

только с полными данными. К сожалению, иногда наблюдаются перебои в работе датчиков загрязнений и профилемера, что порождает пропуски в данных. Наибольший уровень загрязнений наблюдается в зимний период. Нами была выбрана зима 2023-2024 года. Этот выбор обусловлен тем, что для этого периода полные данные составляют 73% от общего количества данных. Это максимум для имеющихся у нас данных.

Результаты. Был проведен корреляционный анализ данных. Сначала были посчитаны корреляции для уровней загрязнений и интенсивности температурной инверсии на высоте от 0 до 1000 метров. Для высот от 200 до 1000 метров максимальное значение корреляции составило 0,075 для уровня загрязнения CO и интенсивности температурной инверсии. Для высот от 0 до 200 метров корреляция интенсивности температурной инверсии со взвешенными частицами составляет 0,53, а с CO составляет 0,56.

Чтобы более детально определить уровни, на которых температурная инверсия сильнее всего коррелирует с уровнем загрязнений, были рассмотрены следующие интервалы высот: 0-50 метров, 50-75 метров, 75-100 метров, 100-150 метров и 150-200 метров. Полученные корреляции показаны в таблице 1.

Таблица 1.

Корреляции параметров.

	h	p	wv	wd	pm25	no2	no	nh3	h2s	so2	co	0-50	50-75	75-100	100-150	150-200
t	-0,16	-0,54	0,33	0,24	-0,37	-0,26	-0,08	0,10	-0,08	-0,08	-0,29	0,29	-0,38	-0,38	-0,44	-0,42
h		0,11	-0,30	-0,31	0,25	0,15	0,18	0,11	0,07	-0,03	0,31	-0,10	0,22	0,22	0,25	0,27
p			-0,57	-0,24	0,37	0,30	0,29	0,10	0,17	-0,14	0,32	-0,16	0,23	0,23	0,26	0,26
wv				0,38	-0,38	-0,33	-0,36	-0,12	-0,22	0,07	-0,40	0,01	-0,25	-0,25	-0,27	-0,28
wd					-0,39	-0,28	-0,27	-0,05	-0,12	-0,04	-0,44	-0,04	-0,25	-0,25	-0,27	-0,29
pm25						0,44	0,61	0,20	0,37	0,07	0,82	0,09	0,52	0,52	0,56	0,58
no2							0,29	0,17	0,09	0,01	0,49	0,08	0,35	0,35	0,38	0,39
no								0,47	0,49	-0,11	0,71	0,17	0,33	0,33	0,34	0,35
nh3									0,22	-0,12	0,32	0,11	0,06	0,06	0,05	0,06
h2s										0,23	0,40	0,06	0,20	0,20	0,21	0,22
so2											0,10	0,02	0,08	0,08	0,10	0,10
co												0,16	0,57	0,57	0,59	0,60
0-50													0,27	0,27	0,07	0,02
50-75														1,00	0,94	0,86
75-100															0,94	0,86
100-150																0,97

Как видно из таблицы 1, сильно скоррелированы уровни угарного газа и взвешенных частиц, а также угарного газа и оксида азота. Максимальные корреляции интенсивности температурной инверсии наблюдаются с уровнями угарного газа и взвешенных частиц. Причем эти корреляции наблюдаются для высот от 50

до 200 метров. Кроме того, сильно скоррелированы интенсивности температурных инверсий для этих высот.

С помощью VidaExpert мы спроецировали многомерные данные в пространство первых трех главных компонент. Это позволяет визуализировать данные. Были рассчитаны главные компоненты для анализируемого набора данных. По методу сломанной трости и методу локтя достаточно использовать первые три главных компоненты. Максимальный вклад в первую главную компоненту вносят следующие параметры: сила ветра, взвешенные частицы, оксид азота, угарный газ и интенсивность температурной инверсии на высоте 150-200 метров. Для второй главной компоненты параметры с максимальным вкладом следующие: температура, давление, аммиак и интенсивность температурной инверсии на высоте 0-50 метров. Для третьей главной компоненты это аммиак, диоксид серы и интенсивность температурной инверсии на высоте 150-200 метров. Результаты проекции показаны на рис. 1. Данные сгруппированы в один плотный кластер и два кластера составляют точки, достаточно далеко отстоящие от основного кластера. Синим цветом обозначен кластер 1, красным кластер 2 и зеленым кластер 3.




Рис. 1. Проекция многомерных данных в пространство первых трех главных компонент.

Рассмотрим состав полученных кластеров. На рис. 2 показаны боксплоты для всех рассматриваемых параметров по трем кластерам. В кластер 1 попали

точки со следующими значениями параметров: температура преимущественно от -18 до -3, средняя влажность и давление. Сила ветра до 2 м/с, от восточного до западного. Низкий уровень загрязнений. Низкая интенсивность приземной и приподнятой инверсии. Посты представлены достаточно равномерно. Низкая интенсивность температурной инверсии способствует низкому уровню загрязняющих веществ. Кластер 2 включает точки, соответствующие следующим значениям: температура преимущественно от -15 до -5, влажность высокая, давление высокое. Ветер слабый, от северного до восточного. Высокий уровень загрязнений, кроме SO₂. Высокая интенсивность температурной инверсии. В кластер попали преимущественно посты Кировский, Сосновоборск и Ветлужанка. Высокая интенсивность температурной инверсии на высоте 50-200 метров способствует накоплению загрязняющих веществ. В кластер 3 попали точки со следующими параметрами: температура преимущественно от -25 до -10, влажность средняя, давление среднее. Сила ветра до 2 м/с, от восточного до южного. Высокий уровень загрязнений по SO₂ и CO. Высокая интенсивность температурной инверсии. В кластер попал преимущественно пост Солнечный. Рядом с постом Солнечный находится источник загрязнения воздуха диоксидом серы. Ветер восточного и южного направления перемещает диоксид серы в сторону поста наблюдения, а температурная инверсия не дает загрязнению рассеиваться.

В таблице 2 показаны состав кластеров по постам и процентное соотношение между кластерами.

Таблица 2.

	1 кластер	2 кластер	3 кластер
Черемушки	1973	91	6
Кировский	2104	257	20
Покровка	1883	34	11
Северный	1783	70	58
Солнечный	1873	0	576

Сосновоборск	1274	139	0
Свердловский	1334	11	44
Ветлужанка	1709	177	0
Количество точек в кластере	13940	785	717
% от общего количества	90,27	5,08	4,64




Рис. 2. Боксплоты параметров для трех кластеров.

Выводы. Таким образом, прослеживается связь между температурной инверсией и уровнем загрязнений. Причем на уровень загрязнений оказывает влияние температурная инверсия на высотах 50-200 метров. Источником загрязнений угарным газом и взвешенными частицами в основном является автотранспорт и

печное отопление. Загрязнения от работы автотранспорта распределены по городу достаточно равномерно и это позволяет увидеть связь температурной инверсии и этих загрязнений. Загрязнения другими веществами связаны с конкретными источниками загрязнений и поэтому более локальны. Тем не менее, высокая интенсивность температурной инверсии влияет и на уровень загрязнений этими веществами.

Список литературы

1. Давыдова И. С., Гапоненко А. В. Проблема загрязнения атмосферного воздуха в городах //Sciences of Europe. – 2017. – №. 14-2 (14). – С. 3-5.
2. Пепина Л. А., Созонтова А. Н. Загрязнение атмосферного воздуха автомобильно-дорожным комплексом //Alfabuild. – 2017. – №. 1. – С. 99-110.
3. Стурман В. И. Природные и техногенные факторы загрязнения атмосферного воздуха российских городов //Вестник Удмуртского университета. Серия «Биология. Науки о Земле». – 2008. – №. 2. – С. 15-29.
4. Krzyzanowski M. et al. Air pollution in the mega-cities //Current Environmental Health Reports. – 2014. – Т. 1. – №. 3. – С. 185-191.
5. Rodríguez M. C., Dupont-Courtade L., Oueslati W. Air pollution and urban structure linkages: Evidence from European cities //Renewable and Sustainable Energy Reviews. – 2016. – Т. 53. – С. 1-9.
6. Chan C. K., Yao X. Air pollution in mega cities in China //Atmospheric environment. – 2008. – Т. 42. – №. 1. – С. 1-42.

МОНИТОРИНГ ТЕЗАУРУСА ИНТЕРИОРИЗИРОВАННЫХ ТЕРМИНОВ С ИСПОЛЬЗОВАНИЕМ ГРАФОВОЙ НОТАЦИИ

В.А. Углев^{1,2}, А.В. Барков¹

¹Сибирский федеральный университет,

²Московский университет МВД России им. В.Я. Кикотя,

uglev-v@yandex.ru

Введение

Освоение человеком новых знаний, теорий, концепций и видов деятельности – классическая задача педагогики. На первоначальном этапе организованного обучения, имеющего в своей основе теоретический базис, всегда начинается с понятий. Понятия (концепты) формируют *тезаурус* (словарь), а затем этот словарь структурируется по в процессе изучения той или иной учебной дисциплины: число понятий постепенно растёт, между ними устанавливаются семантические связи, их значения начинают корректно применяться с учётом контекста [1]. Поэтому базисом для диагностики знаний, а затем и уровня развития компетентностей [2] являются корректно освоенные термины, на которые ложится дальнейшая структура учебных знаний.

Освоенное понятие – это когда человек не только знает (дословно или приблизительно) определение термина, но и применяет его «к месту» в тех жизненных ситуациях, когда в этом возникает объективная необходимость. Проверить усвоение терминов в вопросах, связанных не с практической деятельностью (метание гранаты, вождение автомобиля и пр.), а на этапе усвоения учебных знаний в аудитории можно через диагностику проявления речевых функций (устных объяснений или письменных развёрнутых ответов) [3]. В психологии процесс «внедрения» в личное сознание новых понятий при восприятии и интерпретации окружающей действительности, получил название *интериоризации* (школа Л.С. Выготского, П.Я. Гальперина [4]). Поэтому только когда учащийся начинает не только применять новые термины, но и корректно их использовать в контексте учебной ситуации, - только тогда можно говорить о том, что на уровне терминологии знания были восприняты (компонент *знать*) и могут быть диагностированы

в более широком контексте – проблемных задач, требующих демонстрации практических навыков (компоненты *уметь* и *владеть*).

Аудиторное обучение подразумевает, что учитель своевременно выявляет и поправляет учащегося, если видит, что тот не освоил нужные для учебной темы понятия. Отдельный интерес представляет вопрос контроля корректности сформированности тезауруса при обучении на базе *интеллектуальных автоматизированных обучающих систем* (ИАОС, Intelligent Tutoring Systems [5]). Дело в том, что электронная форма обучения предполагает ведущую роль учащегося при работе с дидактическим материалом (учитель оценивает решения асинхронно и, как правило, не взаимодействуя напрямую с учащимися). Сам учащийся проверить корректность применения терминологии не может, т.к. не интериоризированные понятия он не рефлексировать должным образом или делает это без сложившихся ориентиров. Автоматический анализ ответов алгоритмами искусственного интеллекта, предполагающий выделение концептов и их взаимосвязи, относительно контекста решаемой задачи, может помочь в диагностике процесса интериоризации терминов учебного материала. Но этот подход предполагает наличие соответствующей методики и инструментария. Рассмотрим один из вариантов такого решения, ориентируясь на использование методов когнитивной визуализации при работе с ИАОС.

Процесс оценки полнотекстовых ответов может базироваться на выявлении лингвистической структуры текста, сформированного одним учащимся [6] или группой (коллективная работа [7]). Подобный подход к формированию множества концептов (концептуальной карты) в ИАОС может быть дополнен специальной картой тезауруса, ориентированной на мониторинг динамики освоения учебного материала.

Методика диагностики тезауруса учебной задачи

Решение задачи диагностики интериоризации терминов в контексте письменного выполнения учебного задания предполагает раскрытие структуры тезауруса *D*. Компонентами тезауруса будут концепты (термины и их определения), опирающиеся на семиотическую *модель учебного курса C* [8]. В контексте учебного плана каждая дисциплина определяется иерархией учебного материала

(структурное представление) и соответствующего ему целевого компонента (планируемых к развитию компетенций и/или ЗУВов в виде функционального представления, т.е. прагматика реализации программы дисциплины). Эти иерархии заданы вертикальными (синтактическими связями) и горизонтальными (семантическими). Предполагается, что сформированный банк заданий (практические работы, задачи, тестовые задания) ориентированы не только на проверку уровня знаний, но и на проверку уровня развития компетентностей. Все эти данные задаются априори для электронного курса и будут исходной точкой для последующей индивидуализации при взаимодействии с конкретными учащимися. Дополняет эту структуру данных информация из *модели учащегося*: индивидуальные предпочтения (прагматика), относящиеся как структурным, так и к функциональным элементам представленных иерархий, а также данные о работе с электронным курсом – образовательный цифровой след, формируемый из траектории работы с учебным материалом, решений заданий, ведении диалога и пр. [9]).

Где же в этой структуре тезаурус? Очевидно, что при изучении нового материала, имеющиеся в голове у учащегося термины будут актуализироваться и расширять своё назначение (переосмысляться), а также произойдёт пополнение тезауруса новыми концептами. Но так как заблаговременно мы не видим исходной картины (поля знаний, если использовать терминологию инженерии знаний [10]), то придётся опираться на результаты выполнения заданий входного контроля. Тогда имеем тезаурус дисциплины D , в котором нас будут интересовать определения (концепты), вводимые впервые или привлекаемые из ранее изученного дидактического материала «соседних» дисциплин. Из модели курса нам известно, в какой дидактической единице и в какой последовательности эти термины предъявляются учащемуся для освоения. Так как эти концепты вводятся на этапе составления курса, то их семантические взаимосвязи будут априорно известны (см. рис. 1, построено в [11]). Рассмотрим фрагмент граф терминов D , выделив концепты одной из тем d_i , которые должны быть интериоризированы.

Проверка освоения терминологии производится по результатам проведения контрольно-измерительных мероприятий, т.е. решения одного или более заданий.

Модель задания может включать в себя не только формулировку (условие) решаемой задачи, но и подграф терминов, которые ожидается зафиксировать при ответе. Очевидно, что в ряде случаев исходный тезаурус должен включать синонимы и эквиваленты ключевых терминов. Например, для учебной темы, посвященной генеративному искусственному интеллекту, понятия «большая лингвистическая модель», «БЛМ», «большая фундаментальная модель», «БФМ», «Large Language Model» и «LLM» должны восприниматься в ответе учащегося, исходя из здравого смысла, как эквивалентны [12]. При этом подграф для задания j не обязательно должен совпадать с подграфом из темы d_i , к которой он отнесён: в него могут по необходимости входить ранее изученные термины, а также понятия, характеризующие специфику предметной области задачи и присутствие которых следует ожидать при раскрытии решения учащимся.




Рис. 1. Пример фрагмента графа, описывающего взаимодействие тезауруса дидактической единицы (окрашен зелёным) с терминами из ближайших тем в учебном плане

Теперь сформулируем *задачу мониторинга* интериоризированных терминов. Пусть дан текст T , который автор (учащийся) сформулировал письменно при ответе на задание Q , предполагающее развёрнутый ответ открытой формы (например, эссе или решение задачи). Используем допущение, что текст был написан

самостоятельно (не списан/скопирован и не сгенерирован большой лингвистической моделью) и его объём достаточен для дальнейшей работы (не менее абзаца – от 250 символов). Тогда *методика диагностики* интериоризации концептов тезауруса по результатам обработки текста решения будет включать в себя следующие укрупненные этапы:

1. Обработка ответа ученика

1.1. разделим текст T на предложения, а из предложений выделим концепты (токенизируем);

1.2. сформируем для каждого предложения неориентированный граф, объединяющий концепты, включенные в одно предложение;

1.3. объединим все графы предложений в единый граф $G1$, увеличивая вес (размер) вершины при каждом повторном появлении в объединяемых графах; аналогичным образом увеличим вес (толщину) рёбер для повторяющихся связей.

2. Подготовка априорного тезауруса

2.1. сформируем граф $G2$ по задаче Q из текста условия³;

2.2. дополним этот граф концептами G' , которые ожидается зафиксировать в ответе учащегося (минимально необходимые);

2.3. дополним этот граф концептами той темы, в рамках которой размещено задание (включая синонимы).

3. Выделение общности концептов

3.1. наложим графы $G1$ и $G2$, закрашивая пересечение и увеличивая веса дублирующихся фрагментов;

3.2. выделим вершины графа, которые оказались на пересечении тех концептов, которые использовал учащийся, с теми, которые ожидалось получить в ответе.

4. Концентрация – формирование когнитивной карты диагностики знаний [13] по множеству проверяемых концептов из G' .

5. Оценка

³ Эти термины в рамках задания не проверяются на интериоризацию, т.к. они уже явно использованы в условии задания и их дальнейшая обработка не будет нести значительный объём полезной информации.

5.1. количественная оценка пересечения графа из ответа с графом G' из задания (степень полноты в процентах) по всем терминам сразу (рассчитывается автоматически);

5.2. вектор частных оценок для каждого термина из G' (рассчитывается автоматически);

5.3. автоматическая оценка интеллектуальным планировщиком ИАОС когнитивной карты диагностики знаний для проверяемого фрагмента тезауруса на интериоризацию понятий.

5.4. экспертная оценка преподавателем корректности применения терминологии, используя задание специального типа (оценивается через интерфейсы ИАОС, поэлементно для каждого концепта из G' [14]);

6. Формирование рекомендаций для учащегося и «отчёта» для преподавателя.

Это краткое описание общей логики обработки информации из образовательного цифрового следа (текстовых ответов) учащегося. Упуская специфику формирования и анализа когнитивных карт диагностики знаний, обратимся к примеру для иллюстрации общей идеи.

Эксперимент

Имеется электронный курс «*Математические основы машинного обучения*» для технических специальностей высшей школы, подготовленный таким образом, чтобы можно было его изучать в ИАОС с выделением тезауруса. Рассмотрим фрагмент – тему d_4 «*Введение в механизмы работы искусственных нейронных сетей (ИНС)*». Концепты тезауруса данной части курса приведены в таблице 1.

Таблица 1. Концепты

Дидактическая единица	Вводимый термин
4.1. Биологический прообраз нейрона и мозга	сома, дендрит, синапс, аксон, ядро, межклеточная жидкость, электрический импульс, возбуждение, торможение, передача сигнала
4.2. История появления ИНС	Ф. Розенблатт, М. Минский, нейрокомпьютер, персептрон, Марк-1

4.3. Искусственный нейрон	синаптический вес, функция активации, сумматор, сигмоида, пороговая функция, входной сигнал, выходной сигнал
4.4. Модель искусственной нейронной сети	слой, входной слой сети, выходной слой сети, скрытый слой сети, нейрон активации (смещения), прямое распространение сигнала, обратное распространение сигнала, матрица весов, обучение ИНС
4.5. Логика просчёта простейшей искусственной нейронной сети	отклик нейрона, ответ сети

В дополнение к концептам из таблицы 1, следует привести ранее введённые в этом курсе термины, имеющие к данной теме непосредственное отношение: *машинное обучение, искусственный интеллект, таблица данных, евклидова метрика, кодирование*. Их также следует дополнить общенаучными понятиями, уже известными учащемуся: *функция, нейрон, мозг, обучение, градиент, метрика, расстояние, матрица, ось, дисперсия, плотность, шум, оптимизация, координаты, пространство, итерация, среднее значение, данные, информация, знания* (общий тезаурус см. на рис. 1).

Пусть требуется проверить понимание учащихся механизма прохождения сигнала через модель искусственного нейрона (дидактическая единица $d_{4.3}$). Для этого формулируется задание: «*Перед Вами искусственный нейрон с тремя входами (функция сигмоид с параметром 0.7). Опишите словами процесс прохождения сигнала через нейрон с весами у входов $W=[0.3, 1, 0.6]$, если подавать к нейрону следующие значения $X=[1, 0, 1]$. Каков будет результат просчёта (Y)? Поясните свой ответ*». Очевидно, что термины «*искусственный нейрон, сигмоид, вход нейрона, выход нейрона, функция, вес*» проверять не следует (они уже присутствуют в задании и с высокой вероятностью будут оттуда заимствованы). При этом в формулировке вопроса отдельные понятия были приведены в краткой

форме. Получается, что в процессе ответа ожидается, что будут применены понятия «суммирование, синаптический вес, функция активации, умножение» (G'), второе и третье из которых представляет интерес для проверки гипотез о процессе интериоризации.

Допустим, учащийся дал следующий ответ: *«Искусственный нейрон получает на входе значения полезного сигнала, перемножает его на веса и затем суммирует. Далее, сумма подаётся на функцию активации сигмоиды и на выходе получаем 1 или 0. Более точный расчёт затрудняюсь привести»*. В процессе токенизации будут извлечены термины и сформирован граф $G1$. Результирующий граф, после наложения априорных и апостериорных данных, приведён на рис. 2. Из ответа следует, что общий принцип расчёта приведён корректно, термин «функция активации» стал использоваться корректно и в полной формулировке, а термин «синаптический вес» ещё прочно не вошёл в лексикон учащегося (на рисунке выделен зелёным). Для корректной проверки таких гипотез следует предлагать к решению не одну, а 3-5 заданий, используя специальную меру уверенности (например, критерий Шортлиффа [15]).



Рис. 2. Фрагмент графа, описывающий взаимодействие графа учебной темы с графом интериоризированных знаний из ответа на задание целевой темы

Дальнейший анализ графа сам по себе даёт немного эффекта: концептов много, связи не несут ярко выраженного характера. Внимание при таком представлении рассеивается [16]. Потенциально, далее следует использовать другую графовую нотацию, осуществив концентрацию этих данных – когнитивную. В случае, когда понятий много, то выводить на карту следует только те элементы, которые «интересны» с позиции диагностики проблем интериоризации. Но это тема для отдельной статьи.

Как было отмечено в начале статьи, данные об использовании учащимся терминологии представляют наибольший интерес в динамике. Поэтому фиксировать разницу между ответами на схожие задания по терминологии позволяет увидеть «прогресс» в интериоризацию специальных терминов даже если они используются при изучении различных дидактических единиц электронного учебного курса или даже разных дисциплин. Существенно сократить количество терминов в задании можно, если использовать в комплекте к заданию рисунки и схемы, для которых подробное словесное пояснение (описание) будет излишним.

Нами рассмотрен случай, когда множество ожидаемых терминов задаётся априори на этапе составления задачи. Пока функцию выделения проверяемых терминов к конкретному заданию мы не считаем целесообразным перепоручать алгоритмам искусственного интеллекта. Это требует больших затрат времени на составление контрольно-измерительных материалов, но, оправдывается при организации автоматической проверки и позволяет научно-обоснованно подойти к синтезу текста рекомендаций по работе с терминологией.

Наш опыт организации различных форм контрольно-измерительных мероприятий показывает, что использование большого количества заданий, требующих существенного объёма текста в ответах, за один заход трудно даётся учащимся. Они начинают торопиться, минимизировать текст ответов, пропускать задания. При проведении текущего контроля следует ограничиться 3-5 заданиями. При необходимости их можно комбинировать с иными типами заданий. На этапах входного и итогового контроля следует использовать схожие по семантической структуре наборы заданий.

Заключение

Предложенная выше методика оценки интериоризации понятий тезауруса может быть полезна как при работе с автономной интеллектуальной автоматизированной обучающей системой, так и в паре с преподавателем, осуществляющим мониторинг учебного процесса. Разработанные нами инструментальные решения, позволяющие автоматически формировать графы и проверять гипотезы через специальные типы вопросов могут быть объединены с помощью механизма картирования.

В продолжении данной темы реализовано формирование когнитивной карты диагностики знаний по фрагменту тезауруса на базе сервиса [17], ведутся работы по формированию методики автоматического синтеза естественно-языковой части рекомендаций, касающейся результатов диагностики тезауруса на предмет интериоризации понятий, используемых учащимся.

Список литературы

1. Шишкина Л. П. Контекст как структурный компонент лексикона тезаурусного типа //Язык и культура. – 2010. – №. 3 (11). – С. 99-107.
2. Uglev V.A., Ustinov V.A. The new competencies development level expertise method within Intelligent Automated Educational Systems // Trends in Practical Applications of Heterogeneous Multi-Agent Systems. The PAAMS Collection. Advances in Intelligent Systems and Computing, - 2014. – Vol. 293. – pp. 157-164. DIO: 10.1007/978-3-319-07476-4_19.
3. Выготский Л. С. Развитие высших психических функций: из неопубликованных трудов. – Изд-во АПН СССР, 1960. – 500 с.
4. Гальперин П. Я. К учению об интериоризации //Вопросы психологии. – 1966. – Т. 6. – С. 25-31.
5. Du Boulay B., Mitrovic A., Yacef K. Handbook of artificial intelligence in education. Edward Elgar Publishing. 2023. DIO: 10.4337/9781800375413
6. Bredeweg B. et al. Stargazing live! inspiring with real data in a mobile planetarium and learning through conceptual modelling // International Conference on Intelligent Tutoring Systems. – Cham: Springer Nature Switzerland, 2023. – pp. 257-269.
7. Morita J., Ohmoto Y., Hayashi Y. Integrating knowledge in collaborative concept mapping: cases in an online class setting //International Conference on Intelligent Tutoring Systems. – Cham: Springer International Publishing, 2021. – pp. 99-106.
8. Uglev V. An Approach to Organizing Intelligent Tutoring Systems with Customizable Decision-Making Logic // Intelligent Tutoring Systems. LNCS, vol 15723. Springer, Cham. – 2025. – pp. 47-58. DOI: 10.1007/978-3-031-98281-1_4
9. Углев В.А., Покидько В.Ф. Системный подход к проектированию учебных планов и его графического сопровождения // Робототехника и искусственный интеллект: Материалы XIII Всероссийской научно-технической конференции с международным участием. - Красноярск: ЛИТЕРА-принт, 2021. - С. 263-271.

10. Гаврилова Т. А., Хорошевский В. Ф. Базы знаний интеллектуальных систем. – СПб.: Питер, 2000. – 382 с.
11. Кузнецов М.В., Барков А.В., Шангина Е.А., Углев В.А. Расширение возможностей сервиса визуализации графовых структур // Робототехника и искусственный интеллект: Материалы XVII Всероссийской научно-технической конференции с международным участием. - Красноярск: ЛИТЕРА-принт, 2025. - С. 170-176.
12. Законопроект № 1271570-8 «О поддержке развития технологий искусственного интеллекта в Российской Федерации» от 17 июля 2026. [Электрон. ресурс]. URL: <https://sozd.duma.gov.ru/bill/1271570-8>
13. 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
14. Матинина Е.Л., Углев В.А. Программная реализация экспертно-автоматизированной методики оценивания ответов на задания открытого типа // Потенциал устойчивого инновационного развития: концепции, модели и практическое приложение: Материалы Международной научно-практической конференции. - Уфа: Омега сайнс, 2026. - С. 54-61.
15. Углев В.А. Проверка гипотезы об уровне развития компетентности с использованием критерия Шортлиффа и Бьюкенена // Нейроинформатика, ее приложения и анализ данных: XXV Всероссийский семинар. – Красноярск, 2017.– С. 96-100.
16. Miller G. The magical number seven, plus or minus two: Some limits on our capacity for processing information // Psychological review. – №63(2), 1956. – p 81–97.
17. Смирнов Г.А. Библиотека логики отрисовки когнитивных карт диагностики знаний // Робототехника и искусственный интеллект: Материалы XVII Всероссийской научно-технической конференции с международным участием. - Красноярск: ЛИТЕРА-принт, 2025. - С. 188-194.

ЗАЩИТА КОНФИДЕНЦИАЛЬНОСТИ ИЗОБРАЖЕНИЙ ЛИЦ НА ОСНОВЕ ГЕНЕРАТИВНЫХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

М.Н.Фаворская¹

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

Защита конфиденциальности изображений лиц связана с удалением визуальных идентификационных характеристик на уровне человеческого восприятия. Данная задача имеет два аспекта: анонимизация как предотвращение машинного распознавания личности, например, в социальных сетях и визуальное сокрытие информации об идентичности как шифрование персональных данных в киберпространстве для повышения безопасности и точности распознавания. Генерация синтетических изображений лиц позволяет создавать фотореалистичные, но не существующие в реальном мире лица, на основе исходных изображений реальных людей. При этом гарантируется невозможность извлечения биометрических данных. Помимо защиты конфиденциальности, генерация синтетических изображений лиц применяется для аугментации наборов данных в системах распознавания лиц без нарушения этических и правовых норм, а также в игровых механиках для генерации профилей виртуальных аватаров. Таким образом, задача генерации синтетических изображений лиц является одним из важнейших направлений исследований в теории и практике искусственного интеллекта.

Широкое распространение приложений для распознавания лиц на основе генеративного искусственного интеллекта (Generative Artificial Intelligence, GenAI) потенциально представляет серьезную угрозу для конфиденциальности личности. Традиционные методы анонимизации [1], шифрования [2] и искажений [3] зачастую не справляются с проблемами, которые создает GenAI. В то же время GenAI открывает новые возможности сохранения конфиденциальности, создавая синтетические изображения лиц, которые имеют практическую полезность. Традиционные методы машинного зрения использовали такие подходы, как размы-

тие, пикселизация или маскирование изображения лица, которые уязвимы со стороны сверточных нейронных сетей, успешно идентифицирующих «зашифрованные» изображения. В 2002 году был предложен k -подобный алгоритм (k -same algorithm) составления «среднего» изображения лица из k близких изображений [4]. Однако такой подход теоретически ограничивал количество экземпляров для распознавания и допускал визуальные ошибки выравнивания.

Исторически первыми для синтеза изображений лиц использовались генеративно-сопоставительные сети (Generative Adversarial Networks, GAN), продемонстрировавшие многообещающие результаты. Методы данной группы можно разделить на три категории: методы, основанные на манипулировании атрибутами, методы условной перерисовки областей изображения и методы с заменой идентичности. Однако модели GAN имеют ряд недостатков:

- нестабильность во время обучения [5];
- недостаточная реалистичность [6];
- ограничения в разнообразии, что делает практическое применение GAN проблематичным.

Генеративные диффузионные модели являются альтернативой моделям GAN в задаче сохранения конфиденциальности лиц [7–9]. Если модели GAN основаны на применении технологии генератор – дискриминатор, то диффузионные модели сначала создают синтетические изображения путем постепенного добавления шума к входным изображениям лиц, а затем обучаются обратному процессу шумоподавления. Такой вид генерации обеспечивает лучшее качество и разнообразие относительно моделей GAN. Способ обучения глубоких моделей с использованием большого количества вариаций, похожих на оригинал, предотвращает повторную идентификацию личности, что и обеспечивает конфиденциальность, например, в системах распознавания лиц социальных сетей. Тем не менее, диффузионные модели также не лишены недостатков, хотя они менее значимы относительно моделей GAN:

- недостаточный реализм и визуальная точность мельчайших деталей и текстур;

- отсутствие разнообразия черт лица, связанных с полом, возрастом, национальностью, эмоциями;

- недостаточная устойчивость к сложным атакам с использованием глубоких моделей.

Рассмотрим математические основы функционирования вероятностных диффузионных моделей с шумоподавлением (Denoising Diffusion Probabilistic Models, DDPMs). Приближенное апостериорное распределение $q(\mathbf{x}_{1:T} | \mathbf{x}_0)$, называемое прямым диффузионным процессом, итеративно добавляет гауссовский шум к данным $\mathbf{x}_0$ в соответствии с последовательностью $\beta_1, \dots, \beta_T$ в течение T временных шагов, образуя цепь Маркова, в которой данные на каждом временном шаге $\mathbf{x}_t$ зависят только от данных предыдущего шага $\mathbf{x}_{t-1}$ [10]:

$$q(\mathbf{x}_t | \mathbf{x}_{t-1}) = N(\mathbf{x}_t; \sqrt{1 - \beta_t} \mathbf{x}_{t-1}, \beta_t \mathbf{I}) . \quad (1)$$

Последовательность $\beta_1, \dots, \beta_T$ определяет скорость ухудшения исходных данных. Поскольку прямой и обратный процессы имеют одинаковую функциональную форму при малых значениях t , прямой процесс допускает выборку $\mathbf{x}_t$ на произвольном временном шаге t в замкнутой форме $\alpha_t := 1 - \beta_t$. Тогда распределение на любом шаге t вычисляется по следующей формуле:

$$q(\mathbf{x}_t | \mathbf{x}_0) = N(\mathbf{x}_t; \sqrt{\bar{\alpha}_t} \mathbf{x}_0, (1 - \bar{\alpha}_t) \mathbf{I}) , \quad (2)$$

где $\bar{\alpha}_t := \prod_{s=1}^t \alpha_s$.

Обратный процесс использует обучаемую модель для итеративного шумоподавления и восстановления исходного сигнала $\mathbf{x}_0$, начиная с временного шага T :

$$p_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t) = N\left(\mathbf{x}_{t-1}; \mu_\theta(\mathbf{x}_t, t), \sum_\theta(\mathbf{x}_t, t)\right) , \quad (3)$$

где $p_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t)$ – совместное распределение, определяющее обратный процесс.

Модель обучается путем минимизации вариационной нижней границы отрицательного логарифмического правдоподобия:

$$\mathbb{E} \left[-\log p_{\theta}(\mathbf{x}_0) \right] \leq \mathbb{E}_q \left[-\log p(\mathbf{x}_t) - \sum_{t>1} \log \frac{p_{\theta}(\mathbf{x}_{t-1}|\mathbf{x}_t)}{q(\mathbf{x}_t|\mathbf{x}_{t-1})} \right]. \quad (4)$$

Неявные диффузионные модели шумоподавления (Denoising Diffusion Implicit Models, DDIM), заменяющие цепь Маркова немарковским процессом [11], являются более эффективными для генерации и реконструкции изображений. Шаг обратного шумоподавления определяется следующим образом:

$$\mathbf{x}_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(\mathbf{x}_t - \frac{1-\alpha_t}{\sqrt{1-\alpha_t}} \varepsilon_{\theta}(\mathbf{x}_t, t) \right) + \sqrt{1-\alpha_t} \varepsilon_{\theta}(\mathbf{x}_t, t), \quad (5)$$

где $\varepsilon_{\theta} \square N(0, \mathbf{I})$ – функциональный аппроксиматор плотности данных.

Рассмотрим методы анонимизации изображений лиц с помощью генеративных моделей. В работе [3] предложен фреймворк IdentityDP, построенный на основе глубокой генеративно-состязательной сети с механизмом дифференциальной конфиденциальности (differential privacy, DP). Он включает три этапа: разделение представлений лица (с помощью энкодера идентичности для извлечения признаков лица, энкодера атрибутов для оценки выражения, позы, освещенности, фона и генератора слияния), возмущение ε -IdentityDP (внесение локальных случайных изменений – шум Лапласа) и реконструкция изображения (с использованием генератора слияния с замороженными параметрами и полученных искаженных данных на втором этапе). При этом пользователи сами определяют степень желаемых искажений фотографий перед их загрузкой в социальные сети или в открытый доступ. Загруженные фотографии выглядят похожими на оригиналы, но любая система распознавания определит, что измененные фотографии и оригиналы принадлежат разным людям. Примеры преобразований художественных портретов по данной технике приведены на Рис. 1.



Рис.1. Примеры преобразований художественных портретов: верхний ряд – художественные портреты, нижний ряд – их анонимные представления [3].

Модель RBGAN (Realistic-Generation and Balanced-Utility GAN) [6] генерирует изображения лиц, которые очень похожи на реальные лица, но которые трудно распознать автоматически. Эта модель состоит из предварительно обученного кодировщика биометрических маркеров (landmarks), модуля разделения признаков и модуля генерации с симметричной согласованности для устранения небольших искажений. Использование биометрических маркеров позволяет улучшить детализацию областей глаз, носа и рта. Если модель DeepPrivacy [12] обеспечивает 100% конфиденциальность, а модель CIAGAN [13] удаляет идентификационные характеристики, сохраняя при этом необходимые признаки для распознавания лица, то модель RBGAN является компромиссным решением между сохранением признаков и защитой конфиденциальности.

Методы анонимизации, основанные на атаках с использованием генеративно-состязательных сетей, могут обмануть автоматические системы распознавания, незначительно изменяя изображения. Однако такие методы имеют ограничения. Они требуют специального обучения, а сгенерированные изображения все еще могут быть распознаны вручную. Именно поэтому в настоящее время диффузионные модели считаются более эффективными для решения задачи анонимизации.

Диффузионные модели упрощают обучение, создавая изображение лица с

заданной идентичностью. Диффузионная модель DiffFace [9], выполняющая замену изображений лиц (исходное изображение -> целевое изображение), включает обученный модуль ID-conditional DDPM, модуль выборки биометрических маркеров и модуль смешивания, сохраняющего целевые значения. Диффузионная модель DiffuShield [14] включает три этапа обработки. Сначала создается единое семантическое представление изображения лица для декодирования с помощью DDIM. Затем выполняется добавление лапласова шума в параметры преобразования атрибутов с учетом конкретных требований конфиденциальности. На завершающем этапе синтезируется изображение лица с анонимизированной идентичностью и атрибутами на основе искаженных представлений. В работе экспериментально показано, что модель DiffuShield обеспечивает высококачественные и естественные изображения лиц, совместимые с различными задачами компьютерного зрения, при этом надежно сохраняя конфиденциальность. Модель STP-Diff [15] построена на методе синергетического слияния, который применяет аддитивные возмущения к области лица для целенаправленной защиты и неаддитивные пространственные возмущения фона, которые, как считают авторы, лучше инициализируют последующий процесс скрытой диффузии. Мультимодальное решение на основе визуально-лингвистической диффузионной модели предложено в работе [16]. Семантическая информация используется для восстановления реалистичного фона, а конфиденциальность изображения лица обеспечивается диффузионной моделью.

Процесс визуального сокрытия информации, позволяющей идентифицировать личность, аналогичен анонимизации. В общем случае визуальное сокрытие информации обеспечивается тремя основными способами, а именно, гомоморфным шифрованием, хешированием и преобразованием шаблонов. Следует отметить, что удалось найти небольшое количество работ данного направления.

Авторы работы [17] применили алгоритмы шифрования и дешифрования в виде двоичных паролей для анонимизации и деанонимизации соответственно. Для сокрытия идентичности лица использовалась условная генеративно-состязательная сеть. Модель RiDDLE [18] использует в качестве паролей случайно вы-

бренные скрытые данные и может обучаться сквозным способом. Сначала изображение лица проецируется в скрытое пространство с помощью генератора модели StyleGAN2, который синтезирует высококачественные виртуальные изображения и в то же время сохраняет атрибуты идентичности. Затем скрытое представление подвергается шифрованию с помощью легковесного скрытого шифратора. На этапе шифрования каждый пароль связывается с уникальным идентификатором. На этапе дешифрования истинное изображение восстанавливается при наличии верного пароля, в противном случае возвращается новое обезличенное фотореалистичное изображение лица.

Таким образом, два подхода к защите конфиденциальности изображений лиц – анонимизация и сокрытие визуальной информации преследуют разные цели, используют различные методы и имеют разные применения. В настоящее время генеративные диффузионные модели являются основой методов анонимизации, которые широко применяются в открытых ресурсах. Для закрытых ресурсов шифрование изображений лиц является обоснованной стратегией.

Список литературы

1. Anonymizing K-facial attributes via adversarial perturbations / S. Chhabra et al. // In: Proceedings of the 27th International Joint Conference on Artificial Intelligence (IJCAI'18). — Stockholm, Sweden: AAAI Press. — 2018. pp. — 656–662.
2. On the application of homomorphic encryption to face identification / P. Drozdowski et al. // In: International Conference of the Biometrics Special Interest Group (BIOSIG). — Darmstadt, Germany: IEEE. — 2019. — pp. 1–5.
3. IdentityDP: Differential private identification protection for face images / Y. Wen et al. // Neurocomputing — 2022. — Vol. 501. — pp. 197–211.
4. Sweeney L. k-anonymity: A model for protecting privacy / L. Sweeney et al. // International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems. — 2002. — Vol. 10. — No. 5. — pp. 557–570.
5. Luo Y., Yang Z. DynGAN: Solving mode collapse in GANs with dynamic clustering / Y. Luo, Z. Yang // IEEE Trans. Pattern Anal. Mach. Intell. — 2024. — Vol. 46. — pp. 5493–5503.
6. RBGAN: Realistic-generation and balanced-utility GAN for face de-identification /

- Y. Zhang et al. // Image Vis. Comput. — 2024. — Vol. 141. — 104868.1–104868.13.
7. DiffAM: Diffusion-based adversarial makeup transfer for facial privacy protection / Y. Sun et al. // In: Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2024). — Seattle, WA, USA:IEEE. — 2024. — pp. 24584–24594.
 8. Diff-privacy: Diffusion-based face privacy protection / X. He et al. // IEEE Trans. Circuits Syst. Video Technol. — 2024. — Vol. 34. — pp. 13164–13176.
 9. DiffFace: Diffusion-based face swapping with facial guidance / K. Kim et al. // Pattern Recognit. — 2025. — Vol. 163. — pp. 111451.1–111451.10.
 10. Ho J., Jain A., Abbeel P. Denoising diffusion probabilistic models / J. Ho, A. Jain, P. Abbeel // In: Proceedings of the 34th International Conference on Neural Information Processing Systems (NIPS'20). — Vancouver BC, Canada:Curran Associates Inc. — 2020. — pp. 6840–6851.
 11. Song J., Meng C., Ermon S. (2021) Denoising diffusion implicit models / J. Song, C. Meng, S. Ermon // In: Proceedings of the International Conference on Learning Representations (ICLR 2021). — Online. — 2021. — pp. 1–20.
 12. Hukkelås H., Mester R., Lindseth F. DeepPrivacy: A generative adversarial network for face anonymization / H. Hukkelås et al. // In: Advances in Visual Computing: Proceedings of the 14th International Symposium on Visual Computing, ISVC 2019. — Lake Tahoe, NV, USA:Springer. — 2019. — Part I. — pp. 565–578.
 13. Maximov M., Elezi I., Leal-Taixe L. CIAGAN: Conditional identity anonymization generative adversarial networks / M. Maximov et al. // In: Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR2020). — Seattle, Washington, USA:IEEE. — 2020. — pp. 5447–5456.
 14. DiffuShield: Flexible privacy-preserving synthetic face generation via generative diffusion model / T. Wang et al. // Information Fusion. — 2026. — Vol. 125. — pp. 103451.1–103451.11.
 15. STP-Diff: Synergistic fusion of spatial transformation perturbations and diffusion models for robust face privacy protection / M. Li et al. // Information Fusion. — 2026. — Vol. 129. — pp. 104069.1–104069.16.
 16. Enhancing usability in face privacy protection via vision-language guided diffusion

- model / Z. Xu et al. // Information Sciences. — 2026. — Vol. 725. — pp. 122736.1–122736.14.
17. Password-conditioned anonymization and deanonymization with face identity transformers / X. Gu et al. // In: Proceedings of the European Conference on Computer Vision (ECCV 2020). — Glasgow, UK: Springer. — 2020. — pp. 727–743.
18. RiDDLE: Reversible and diversified de-identification with latent encryptor / D. Li et al. // In: Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR2023). — Vancouver, BC, Canada:IEEE. — 2023. — pp. 1–10.

СПИСОК ДОКЛАДОВ

Е.Е. Баранчикова, С.И. Барцев КЛЕТОЧНО-АВТОМАТНАЯ МОДЕЛЬ ХИМИЧЕСКОЙ СООРГАНИЗАЦИИ КЛЕТОК С ДИФФУЗНОЙ ПЕРЕДАЧЕЙ НЕЙРОМЕДИАТОРОВ	3
Н.М. Богатов, А.Н. Богатова, А.Л. Еремин, С.А. Сухих НЕЙРОННО-ИНФОРМАЦИОННЫЕ ПРОЦЕССЫ В МОЗГЕ	10
Н.А.Буряк, О.С.Володько ПРОГНОЗИРОВАНИЕ КОНЦЕНТРАЦИИ УГЛЕКИСЛОГО ГАЗА В АТМОСФЕРЕ ЦЕНТРАЛЬНОЙ СИБИРИ НА ОСНОВЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ВРЕМЕННЫХ РЯДОВ	17
М.V. Gorshkov, Z.M. Shibzukhov DISTILLING TEXTURE LOSSES THROUGH PROJECTED DESCENT DIRECTIONS	24
М.Г. Доррер, Т.А. Шалыгина, А.И. Дудник ВОССТАНОВЛЕНИЕ ПАРАМЕТРОВ ТАКТИЛЬНОГО КОНТАКТА ПО ДАННЫМ МАГНИТНОГО СЕНСОРА: ОТ ПОПИКСЕЛЬНОЙ КЛАССИФИКАЦИИ К ФИЗИЧЕСКИ-ИНФОРМИРОВАННОЙ ПАРАМЕТРИЗАЦИИ	31
Е.Д.Карепова, А.В. Филиппов, Ю.В.Шанько ИССЛЕДОВАТЕЛЬСКИЙ АНАЛИЗ ДАННЫХ ДОЛГОСРОЧНОГО МОНИТОРИНГА ПРИЗЕМНОГО СЛОЯ АТМОСФЕРЫ В КРАСНОЯРСКОЙ ПРОМЫШЛЕННОЙ АГЛОМЕРАЦИИ	41
Г.М. Маркова, С.И. Барцев	

СВЯЗЬ СХОДСТВА СТИМУЛОВ ВНЕШНЕЙ СРЕДЫ И СООТВЕТСТВУЮЩИХ ВНУТРЕННИХ СОСТОЯНИЙ НЕЙРОСЕТЕВЫХ МОДЕЛЬНЫХ ОБЪЕКТОВ	51
Е.Л. Матинина, В.А. Углев ЭКСПЕРИМЕНТАЛЬНАЯ АПРОБАЦИЯ МЕТОДИКИ АВТОМАТИЗИРОВАННОЙ ОЦЕНКИ УРОВНЯ РАЗВИТИЯ КОМПЕТЕНТНОСТЕЙ ПО ЗАДАНИЯМ С ВОПРОСАМИ ОТКРЫТОЙ ФОРМЫ	58
А.С. Михалев, И.С. Садовский, А.А. Савченко, С.А. Борисов, А.Г. Борисов ФАКТОРНАЯ СТРУКТУРА ИММУНИТЕТА У ЗДОРОВЫХ ЛЮДЕЙ	65
Д.Н. Наталенко ОЦЕНКА ЗНАЧИМОСТИ ЛОКАЛЬНОЙ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ ДИКИХ ЖИВОТНЫХ ДЛЯ РАСПОЗНАВАНИЯ И ПОВТОРНОЙ ИДЕНТИФИКАЦИИ	74
Н.Ф. Овчинникова, А.Г. Тутынин К ВОПРОСУ ИЗУЧЕНИЯ ГОРНЫХ ЛЕСОВ	83
Н.В. Саидов КРИТЕРИИ ВЫБОРА МОДЕЛИ СЕГМЕНТАЦИИ ЗАМАСКИРОВАННЫХ ОБЪЕКТОВ ЖИВОЙ ПРИРОДЫ НА ИЗОБРАЖЕНИЯХ	92
М.Ю. Сенашова ВЛИЯНИЕ ТЕМПЕРАТУРНЫХ ИНВЕРСИЙ НА УРОВЕНЬ ЗАГРЯЗНЕНИЯ ПРИЗЕМНОГО СЛОЯ АТМОСФЕРЫ В КРАСНОЯРСКЕ В ЗИМНИЙ ПЕРИОД	100

В.А. Углев, А.В. Барков

МОНИТОРИНГ ТЕЗАУРУСА ИНТЕРИОРИЗИРОВАННЫХ
ТЕРМИНОВ С ИС-ПОЛЬЗОВАНИЕМ ГРАФОВОЙ НОТАЦИИ 106

М.Н.Фаворская

ЗАЩИТА КОНФИДЕНЦИАЛЬНОСТИ ИЗОБРАЖЕНИЙ ЛИЦ НА
ОСНОВЕ ГЕНЕРАТИВНЫХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ 117

СПИСОК АВТОРОВ

ФИО	Место работы	Стр.
Баранчикова Екатерина Евгеньевна	660041 г. Красноярск, пр. Свободный, 79, Сибирский федеральный университет E-mail: katia.krasnoyarsk@yandex.ru	3
Барков Алексей Владимирович	662971, Красноярский край, Железногорск, ул. Кирова, 12-а, СФУ E-mail: aleksey.barkov@gmail.com	106
Барцев Сергей Игоревич	660036, Красноярск, ул. Академгородок, строение 50, Институт биофизики СО РАН E-mail: bartsev@yandex.ru	3, 51
Богатов Николай Маркович	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: bogatov@phys.kubsu.ru	10
Богатова Анна Николаевна	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: anna_bogatova@mail.ru	10
Борисов Александр Геннадьевич	660022, Красноярск, НИИ медицинских проблем Севера — обособленное подразделение ФИЦ КНЦ СО РАН E-mail: 2410454@mail.ru	65
Борисов Сергей Александрович	660123, Красноярск, КГБУЗ «Красноярская межрайонная клиническая больница № 20 имени И.С. Берзона» E-mail: s.borisov@krasgkb20.ru	65
Буряк Никита Александрович	660036, г. Красноярск, Федеральный исследовательский центр «Красноярский	17

	научный центр Сибирского отделения Российской академии наук» E-mail: buryakna98@gmail.com	
Володько Ольга Станиславовна	660036, г. Красноярск, Институт вычислительного моделирования Сибирского отделения Российской академии наук обособленное подразделение ФИЦ КНЦ СО РАН E-mail: osv@icm.krasn.ru	17
Горшков Максим Витальевич	107140, г. Москва, Московский педагогический государственный университет, Институт математики и информатики E-mail: mvgorshkofff@gmail.com	24
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	31
Дудник Александр Иванович	660010, г. Красноярск, ул. Академика Вавилова, д. 11, оф. 2-18, Общество с ограниченной ответственностью «ИнтеллектСистемы» E-mail: heavenrise@yandex.ru	31
Еремин Алексей Львович	350040, г. Краснодар, ул. Ставропольская, 149 ФГБОУ ВО «Кубанский государственный университет» E-mail: aereimin@yandex.ru	10
Карепова Евгения Дмитриевна	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: e.d.karepova@icm.krasn.ru	41
Маркова Галия Муратовна	660036, Красноярск, ул. Академгородок, строение 50, Институт биофизики СО РАН	51

	E-mail: irvingstone@bk.ru	
Матинина Евгения Леонидовна	662971, Красноярский край, Железногорск, ул. Кирова, 12-а, СФУ E-mail: Ewg.2017@yandex.ru	58
Михалев Антон Сергеевич	660074, Красноярск, Сибирский федеральный университет, Институт космических и информационных технологий, кафедра «Программная инженерия» E-mail: asmikhalev@yandex.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	74
Овчинникова Наталья Феликсовна	660036, Красноярск, Институт леса им. В.Н.Сукачева, ФИЦ КНЦ СО РАН E-mail: nf@ksc.krasn.ru	83
Савченко Андрей Анатольевич	660022, Красноярск, НИИ медицинских проблем Севера — обособленное подразделение ФИЦ КНЦ СО РАН E-mail: aasavchenko@yandex.ru	65
Садовский Иван Сергеевич	660022, Красноярск, НИИ медицинских проблем Севера — обособленное подразделение ФИЦ КНЦ СО РАН E-mail: sadovskii24@rambler.ru	65
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	92

Сенашова Мария Юрьевна	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: msen@icm.krasn.ru	100
Сухих Станислав Алексеевич	350040, г. Краснодар, ФГБОУ ВО «Кубанский государственный университет», ул. Ставропольская, 149 E-mail: suhih_52@mail.ru	10
Тутынин Артем Геннадьевич	649000, Республика Алтай, г. Горно-Алтайск, ул. Потанина, д. 11, ООО "Форест ОС" E-mail: sibkub@yandex.ru	83
Углев Виктор Александрович	662971, Красноярский край, Железногорск, ул. Кирова, 12-а, СФУ E-mail: uglev-v@yandex.ru	58, 106
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	117
Филиппов Алексей Владимирович	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: lexa97777@gmail.com	41
Шалыгина Таисия Александровна	660010, г. Красноярск, ул. Академика Вавилова, д. 11, оф. 2-18, Общество с ограниченной ответственностью «ИнтеллектСистемы» E-mail: leonova.ta@inbox	31
Шанько Юрий Вадимович	660036, Красноярск, Академгородок, дом. 50, стр. 44, Институт вычислительного моделирования СО РАН E-mail: shanko@icm.krasn.ru	41

Шибзухов Заур Мухадинович	107140, г. Москва, Московский педагогический государственный университет, 125412, г. Москва, Федеральное государственное бюджетное учреждение науки Институт теоретической и прикладной электродинамики Российской академии наук (ИТПЭ РАН), ул. Ижорская, д. 13, стр. 6 E-mail: szport@gmail.com	24
------------------------------	--	----

Научное издание

Нейроинформатика, её приложения и анализ данных

Материалы XXXIV Всероссийского семинара 25 сентября 2026 года

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

Подписано в печать «15» августа 2026 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