

АНДРИКОВ Д.А.,

к.т.н., доцент, МГТУ им. Н.Э.Баумана, Москва, Россия,
e-mail: andrikov@bmstu.ru

АНДРИКОВ ДМ.А.,

к.т.н., доцент, Инженерная академия, РУДН, Москва, Россия,
e-mail: andrikov-dman@rudn.ru

БЕРЕЗКИН Д.В.,

к.т.н., доцент, МГТУ им. Н.Э.Баумана, Москва, Россия,
e-mail: berezkind@bmstu.ru, ORCID ID 0000-0001-7149-6072

ПОПОВ А.Ю.,

д.т.н., доцент, МГТУ им. Н.Э.Баумана, Москва, Россия,
e-mail: alexpopov@bmstu.ru

ПРОЛЕТАРСКИЙ А.В.,

д.т.н., профессор, МГТУ им. Н.Э.Баумана, Москва, Россия, e-mail: pav@bmstu.ru

НЕЙРОСЕТЕВАЯ ГРАФОВАЯ АРХИТЕКТУРА ПРОЗРАЧНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В МЕДИЦИНЕ

DOI: 10.25881/18110193_2025_2_70

Аннотация. В статье представлен подход к созданию информационной системы на основе нейросетевой графовой архитектуры. Этот подход призван снивелировать проблему явного объяснения решений, принимаемых искусственным интеллектом — проблема прозрачности (объяснимости, надежности, доверенности). Использование технологий искусственного интеллекта в медицине носит «сквозной» характер и способствует созданию условий для улучшения эффективности и формирования принципиально новых направлений деятельности: автоматизации рутинных (повторяющихся) операций; использования автономного интеллектуального оборудования и робототехнических комплексов, интеллектуальных систем управления; повышения эффективности процессов планирования, прогнозирования и принятия врачебных решений. Перспективной технологией предлагаемого подхода является применение графовой нейросетевой архитектуры в составе информационной системы для обработки и анализа данных. В статье реализован пример классификации узлов графов на открытом датасете с кардиоданными условно-здоровых людей и пациентов.

Ключевые слова: прозрачный искусственный интеллект, тераграф, графовые нейронные сети.

Для цитирования: Андриков Д.А., Андриков Дм.А., Березкин Д.В., Попов А.Ю., Пролетарский А.В. Нейросетевая графовая архитектура прозрачного искусственного интеллекта в медицине. Врач и информационные технологии. 2025; 2: 70-83. doi: 10.25881/18110193_2025_2_70.

ANDRIKOV D.A.,

PhD, Associate Professor, Bauman Moscow State Technical University, Moscow, Russia,
e-mail: andrikov@bmstu.ru

ANDRIKOV DM.A.,

Ph.D., Associate Professor, Engineering Academy, RUDN University, Moscow, Russia,
e-mail: andrikov-dman@rudn.ru

BEREZKIN, D.V.,

PhD, Associate Professor, Bauman Moscow State Technical University, Moscow, Russia,
e-mail: berezkind@bmstu.ru

POPOV A.IU.,

DSc, Associate Professor, Bauman Moscow State Technical University, Moscow, Russia,
e-mail: alexpopov@bmstu.ru

PROLETARSKY A.V.,

DSc, Professor, Bauman Moscow State Technical University, Moscow, Russia, e-mail: pav@bmstu.ru

NEURAL NETWORK GRAPH ARCHITECTURE OF TRANSPARENT ARTIFICIAL INTELLIGENCE IN MEDICINE

DOI: 10.25881/18110193_2025_2_70

Abstract. *The paper presents an approach to design an information system based on a neural network graph architecture. This approach is designed to mitigate the problem of explicit explanation of decisions made by artificial intelligence — the problem of transparency (explainability, reliability, trustworthiness). The use of artificial intelligence technologies in medicine has a “transversal” character and contributes to the creation of conditions for improving efficiency and formation of fundamentally new areas of activity: automation of routine (repetitive) operations; use of autonomous intelligent equipment and robotic complexes, intelligent control systems; increasing the efficiency of planning, forecasting and medical decision-making processes. A promising technology of the proposed approach is the use of graph neural network architecture as part of the information system for data processing and analysis. In this article we introduce an example of graph node classification on an open dataset with cardio-data of conditionally healthy people and patients.*

Keywords: *Explainable AI, Teragraph, Graph Neural Network.*

For citation: Andrikov D.A., Andrikov Dm.A., Berezkin, D.V., Popov A.Iu., Proletarsky A.V. Neural network graph architecture of transparent artificial intelligence in medicine. Medical doctor and information technology. 2025; 2: 70-83. doi: 10.25881/18110193_2025_2_70.

ВВЕДЕНИЕ

В целях развития искусственного интеллекта в России указом Президента Российской Федерации от 10 октября 2019 г. № 490 утверждена Национальная стратегия развития искусственного интеллекта (ИИ) до 2030 года в Российской Федерации и стратегией определены шесть задач для регулирования, взаимодействия и развития в области ИИ — это поддержка научных исследований, разработка и развитие программного обеспечения, повышение доступности и качества данных, повышение доступности аппаратного обеспечения, повышение уровня обеспечения российского рынка технологий искусственного интеллекта квалифицированными кадрами и уровня информированности населения о возможных сферах использования таких технологий, создание комплексной системы регулирования общественных отношений.

Появление новых медицинских устройств, использующих ИИ, привело к дискуссии о том, должна ли логика, лежащая в основе ИИ, быть понятной врачу и пациенту не с точки зрения математических преобразований входных данных в выходные, а с точки зрения принятых в отрасли логических шагов принятия решений. Иными словами, переходя к широко используемой в кибернетике аналогии «черного ящика», технология медицинского ИИ должна быть «прозрачной», то есть прозрачность (или объяснимость, доверенность) можно понимать как характеристику системы, управляемой ИИ, позволяющую человеку восстановить, почему ИИ пришел к тем или иным выводам [1].

Подход к построению архитектуры прозрачного искусственного интеллекта в медицине базируется на концептуальном подходе рассматривать ИИ как часть информационных технологий, способную решать сложные задачи в областях, где накоплены большие наборы размеченных (заранее подготовленных экспертом с соответствующими отметками для обучения ИИ) данных, но для которых нет четких однозначных правил принятия решений [2]. Примеры организации работы с медицинскими данными на основе машинного обучения можно найти в обзоре [3] или монографии [4], где представлен мировой опыт [5] и раскрыты общетеоретические вопросы терминологии цифровой медицины, понятия технологий ИИ, этапы жизненного цикла набора данных.

В работе [6] используют методы машинного обучения в области диагностики неврологических заболеваний, в частности графовые нейронные сети (GNN), для анализа структурных и функциональных сетей мозга. В работе предложен математический метод, который сочетает графовые сверточные слои с особым механизмом пулинга для выявления ключевых областей мозга, связанных с заболеваниями, такими как аутизм и болезнь Альцгеймера. Этот подход демонстрирует высокую эффективность в классификации пациентов, подчеркивая важность учета топологических свойств функциональных сетей мозга. Исследуются нарушения сегрегации функциональных сетей при большом депрессивном расстройстве, используя консенсусные сети и метрики, такие как коэффициент кластеризации, которые показали высокую диагностическую точность. Подтверждено, что графовые нейронные сети позволяют эффективно анализировать сложные взаимодействия между регионами мозга, выявляя биомаркеры заболеваний. Разработанные методы оценки устойчивости кластеризации и стратификационные биомаркеры открывают путь к персонализированной медицине, где выбор терапии будет основываться на индивидуальных особенностях организации нейросетей.

Отдельные элементы прозрачного ИИ были реализованы в виде объединения возможностей программными средствами сузить количество «подозрительных» участков записи ЭЭГ в задачи экспресс-диагностики эпилепсии. Симбиоз ИИ и врача оказался весьма успешным (симбиозом здесь назван программный комплекс, который объединил прикладное программное обеспечение для загрузки датасетов, интерфейсную составляющую для организации работы с пользователем и алгоритмическое программное обеспечение машинного обучения), и система в настоящее время внедряется в клиническую практику [7]. Программный комплекс анализирует участки записи ЭЭГ, которые вероятно могли содержать эпилептические приступы с последующей интерпретацией этих данных естественным интеллектом врача [8].

К архитектуре прозрачного ИИ выдвигаются требования интерпретируемости в смысле прослеживаемости и объяснимости выводов и решений. Архитектура создается параллельно

с развитием новых технологий обработки данных и созданием для разработчиков технологий ИИ, включающего инструментарий обработки и визуализации данных, моделей машинного обучения, создания открытых библиотек, испытательных стендов и других инструментов. Одним из подходов к созданию алгоритмического программного обеспечения прозрачного ИИ является графовый метод представления информации, совмещенный с технологиями нейронных сетей [9].

В статье приведен один из возможных подходов, продолжающих развитие алгоритмов в [6] и [1] к созданию архитектуры ИИ как прообраза взаимосвязей информационных технологий, требований к ресурсному обеспечению и внедрению новой электронной компонентной базы, специально создаваемой для эффективной реализации алгоритмов обработки данных, используемых в технологиях ИИ на основе нейросетевой графовой архитектуры. Приведен пример алгоритма машинного обучения для классификации пациентов с кардиологическими данными. Пример выполнен на отечественной платформе Тераграф (Патент №71016 «Электронная вычислительная машина с многими потоками команд и одним потоком данных») на общедоступном Jupiter Notebook на распространенном языке программирования Python и открытой лицензией на распространение и использование.

МАТЕРИАЛЫ И МЕТОДЫ

В качестве метода достижения цели реализовано создание новых математических моделей графовых вычислений, адаптированных для широкого круга разработчиков (этим объясняется выбор широко распространенного языка Python).

В качестве примера для реализации используется открытый датасет [11] включающий три ключевых компонента: PhysioBank, PhysioToolkit и собственно PhysioNet [10]. PhysioBank представляет собой обширный архив многопараметрических записей физиологических сигналов, таких как ЭКГ, ЭЭГ, сигналы дыхания и другие.

Данный ресурс стал стандартом де-факто в исследованиях физиологических сигналов благодаря нескольким ключевым особенностям: предоставлению бесплатного доступа к клинически значимым данным, использованию стандартизированных форматов записей (WFDB format), наличию инструментов для анализа нелинейной динамики физиологических систем и возможностям воспроизведения исследований. Особую ценность представляют базы данных по анализу вариабельности сердечного ритма, детекции аритмий, исследованиям сна и нейрофизиологии.

В области машинного обучения данные PhysioBank активно используются для решения таких задач, как классификация ЭКГ-сигналов, прогнозирование сердечных событий и разработка методов глубокого обучения для анализа

Таблица 1 — Примеры числовых данных исследуемого датасета (разбито на две таблицы, индекс таблицы — столбец №). Столбец Count_subj — это вспомогательный столбец, в котором указано сколько раз присутствует в датасете запись для конкретного испытуемого (subject_id)

№	Subject_id	Count_subj	Study_id	Date	Report
0	19557662	27	40000017	27.06.2015	0.037353
1	18477137	93	40000029	27.06.2015	0.037353
2	16598616	3	40000035	28.06.2015	-0.009072
3	16368287	7	40000079	15.07.2015	0.002092
4	12576058	43	40000115	23.03.2016	0.002092

№	rr_interval	p_onset	p_end	qrs_onset	qrs_end	t_end	p_axis	qrs_axis	t_axis	Healthy Status
0	659	40	128	170	258	518	81	77	79	0
1	722	40	124	162	246	504	77	75	70	0
2	600	40	130	162	244	474	79	72	77	1
3	659	40	146	180	254	538	79	66	69	1
4	952	40	146	198	282	598	24	80	20	1

медицинских временных рядов. Для работы с этими данными разработаны специализированные библиотеки, например, пакет wfdb для языка Python, позволяющий легко загружать и обрабатывать записи физиологических сигналов.

Датасет [11] содержит следующие параметры: Описания столбцов базы данных machine_measurements.csv

1. Subject_id — идентификатор субъекта (пациента или условно здорового) в базе данных MIMIC-4.
2. Study_id — идентификатор для конкретного исследования, с которым связана диагностическая ЭКГ. Данные в этом столбце могут использоваться для отслеживания всех диагностических данных, связанных с одним конкретным исследованием. Для каждой записи был создан уникальный идентификатор исследования. Это аналог уникальной записи приёма в электронной медицинской карте.
4. Date — дата, когда была сделана диагностическая ЭКГ. Эта информация важна для временной маркировки данных и связывания событий с конкретным моментом времени. В связи с требованиями сохранять конфиденциальность данных абсолютное значение времени было зашифровано, но относительные временные последовательности для одного и того же пациента сохранены.
5. report — текстовый отчет по кардиологии, превращенный с помощью токенизации процедурой Word2Vec в числовой признак.
6. rr_interval — время между последовательным R-волнами на ЭКГ в миллисекундах. Это измерение отражает частоту сердечных сокращений или ритм сердца.
7. qrs_onset — время начала комплекса QRS на ЭКГ в миллисекундах. QRS комплекс отражает активацию сердечных желудочков.
8. qrs_end — время окончания комплекса QRS на ЭКГ в миллисекундах.
9. t_end — время окончания T-волны на ЭКГ в миллисекундах. T — волна отражает восстановление желудочков сердца.
10. p_axis — электрическая ось P-волны в градусах. Она отражает направление распространения возбуждения в предсердиях.
11. qrs_axis — электрическая ось QRS-комплекса в градусах. Она отражает направление распространения возбуждения в желудочках.

12. t_axis — представляет угловые измерения направления оси T-волны для каждой записи в наборе данных.

13. Heathy_Status — бинарный показатель (маркер) отнесения к здоровому или клиническому состоянию. Показатель принимает значение 0 (пациент) или 1 (здоров). Назначение показателя выполнено на основе описания в столбце report.

Набор данных MIMIC-IV-ECG (Medical Information Mart for Intensive Care — Electrocardiograms), доступный на платформе PhysioNet [11], представляет собой крупномасштабную базу электрокардиографических записей, связанных с клиническими данными пациентов. Этот ресурс является частью расширенной версии MIMIC-IV (версия 1.0) и содержит 812537 стандартных 12-канальных электрокардиограмм, записанных у 272384 пациентов в период с 2011 по 2019 год в медицинском центре Beth Israel Deaconess (Бостон, США). Для демонстрационного примера сделаем выборку из 10000 записей из этой базы. Параметры статистического распределения данной выборки указаны на рисунке 1. Для этой выборки характерна классическая ситуация с неравенством классов: из 17000 записей условно здоровых содержится 5000 испытуемых.

Для анализа этого датасета можно применять множество методов машинного обучения, в том числе с использованием открытых AutoML фреймворков. Цель исследования — разработка такой архитектуры (совокупной взаимосвязи аппаратной платформы и программных алгоритмов), которая поддержит формирование инженерных практик верификации разнородных данных, данных со слабой разметкой (как в предлагаемом примере, рисунок 1 и таблица 1).

Для обеспечения высокого качества данных перед анализом был реализован метод обнаружения дублирующихся записей на основе уникального идентификатора пациента (subject_id). Сначала идентифицируются все строки с повторяющимися значениями в указанном поле, затем результаты сортируются для удобства последующего анализа. Это позволяет сохранить все экземпляры записей, формируя их в цепочки событий особого типа, который будет называться ArrayArrowData. Это особенно важно в медицинских исследованиях, где необходимо учитывать все случаи обращений пациентов.




Рисунок 1 — Статистические характеристики параметров датасета с кардиоданными пациентами и условно-здоровых. Показан выборка для 17 тысяч записей.




Рисунок 2 — Распределение цепочек событий в датасете. По оси ординат указана длина записей в исследуемом датасете (количество визитов пациента к врачу). По оси абсцисс номер уникальной цепочки ArrayArrowData.

Цепочка ArrayArrowData — это временная последовательность встречаемости обезличенного уникального идентификатора пациента в датасете.

Цепочка временных последовательностей сгруппирована по уникальным subject_id пациентов. Всего уникальных цепочек ArrayArrowData.Size = 967.

Полученный набор дублированных строк сортируется по идентификатору пациента, что обеспечивает логичную группировку записей для анализа. Такой подход обеспечивает комплексную проверку данных, сохраняя при этом все атрибуты оригинальных записей, что

критически важно для последующего клинического анализа. Реализация основана на библиотеке pandas. Таким образом, для анализа сформирован датасет с более чем 967 записями, содержащими цепочки медицинских событий (рисунок 2).

РЕЗУЛЬТАТЫ РАЗРАБОТКИ

Платформа, как универсальный инструмент для решения прикладных задач, представляет собой «конструктор» программных решений модульного типа, включающий распределенные ресурсы обработки данных, набор цифровых библиотек, наборы данных (dataset), средств визуализации, программных коннекторов, программных интерфейсов взаимодействия (API) и модулей ИИ. В целях обеспечения технологического лидерства и поддержки образовательных программ развития ИИ в медицине проект программного кода доступен по открытой лицензии и расположен по ссылке <https://github.com/TAUforPython/BioMedAI>.

Представление данных в виде графа

Программный код для графовых моделей визуализирует временные взаимосвязи между медицинскими событиями пациента, используя графовое представление данных (рис. 3). В

основе модели лежит преобразование структурированных медицинских записей в ориентированный мультиграф, где узлы соответствуют уникальным идентификаторам пациентов (subject_id), а рёбра представляют отдельные медицинские события с привязанными к ним временными метками (Date) и токенизированными текстовыми описаниями (report).

Характеристики модели: временную привязку событий через атрибут edge_key, использующий дату проведения (Date) в качестве уникального идентификатора ребра и семантическое кодирование медицинских событий через токенизированные текстовые описания (report), присваиваемые в качестве весов рёбер (weight).

Метод преобразует исходные табличные данные в графовую структуру с использованием мультиграфа (MultiGraph) библиотеки Networkx. Разная визуализация обеспечивает наглядное представление временных последовательностей




Рисунок 3 — Разные варианты изображения графа для одного пациента.
Имена узлов — обезличенные характеристики приёмов (report).
Цвет узла отражает статус пациент (красный)
или условно здоровый (синий).




Рисунок 4 — Представление датасета в виде графа типа А (circular) и В (spring).
Красные ребра показывают переход в статус пациента.
На графе изображено 4 тыс. медицинских событий
из исследуемого датасета.

медицинских событий, где пространственное расположение узлов косвенно отражает хронологию событий с весом report (рисунок 3).

Основываясь на этом подходе, применим графовую модель для изображения цепочек событий исследуемого датасета [11] (см. рисунок 4).

Анализ связей на рисунке 4 приводит к необходимости разработки такого алгоритма машинного обучения, который бы учитывал взаимное расположение узлов. Это позволит учитывать изменение состояния здоровья пациента. В текущей модели датасета выдвигается гипотеза о возможности классифицировать узлы графа по бинарной классификации статус здоров/пациент. Для этого применяется графовая нейросетевая модель.

Программная реализация графовой нейронной сети

Программный код для её реализации создает графовую нейронную сеть (GNN), обеспечивающий обработку структурных данных. На вход модели поступают три основных компонента: признаки узлов (`node_features`), информацию о рёбрах графа (`edges`) и их веса (`edge_weights`).

Код состоит из нескольких ключевых компонентов. Сначала применяется преобразующий полносвязный слой (`preprocess`) для преобразования исходных признаков узлов. Затем следуют два последовательных графовых свёрточных слоя (`conv1` и `conv2`), каждый из которых включает механизмы `dropout` для регуляризации. Особенностью архитектуры является использование `skip-connection` между слоями, где выход каждого графового слоя суммируется с его входом, что помогает избежать проблемы исчезающих градиентов. После графовых слоёв применяется постобработывающий полносвязный слой (`postprocess`), за которым следует финальный слой (`compute_logits`) для вычисления выходных логитов классификации.

Для реализации программного кода необходимо представление следующих специальных информационных баз и моделей:

- хранилище первичной информации содержит мультимодальную информацию о прецедентах, результатах обследований, поставленных диагнозах в изначальной формулировке, предложенных вариантов лечения. Хранилище является темпоральным, дополняется и обновляется в соответствии

с изменениями, вносимыми задействованными медицинскими учреждениями. Новые фактологические данные, опровергающие или дополняющие ранее полученные, вносятся в хранилище в соответствии с процедурой формирования темпоральных данных. Хранилище обрабатывается с целью выделения значимых медицинских прецедентов, используемых в системе (см. рисунок 5):

- хранилище результатов логического вывода содержит последовательности прецедентов, использованных в процессе работы системы для выработки результатов. В качестве результатов могут выступать прецеденты, линейные треки из последовательности прецедентов, деревья решений на прецедентах. Документирование результатов логического вывода обеспечивает основные качества системы: возможность анализа ошибок в работе системы и их исправление, и как следствие, непрерывное повышение качества работы системы;
- хранилище графовых моделей используется для долговременного хранения множества частных моделей. Частные модели представляют собой совокупность прецедентов, относящихся к конкретному пациенту или группе пациентов. Модели данного типа используются для предиктивного анализа развития процессов у пациента, и выработки частных логических выводов;
- хранилище нейросетевых моделей используется для долговременного хранения, выборки и обновления моделей автоматической нейросетевой классификации и идентификации, патологических паттернов и эталонов.
- словарь уникальных кодов вершин используется для представления графовых моделей в форме, максимально пригодной для обработки информации. В частности, выполняется выделение структурной части информации (связей между различными объектами, категориями и фактами), и отделение ее от информационной составляющей (атрибутов, временных параметров). Использование раздельного хранения индексной и информационных частей позволяет повысить скорость работы системы на вычислительном комплексе Тераграф (Патент №71016 «Электронная вычислительная машина с многими потоками команд и одним потоком данных»);




Рисунок 5 — Структурно-функциональная схема ИТ системы для анализа медицинских данных.

- основной граф знаний (граф ДеБрюйна) содержит информацию о прецедентах, представленную таким образом, чтобы ускорить механизмы поиска и анализа схожих прецедентов и треков. На основе поиска по графу ДеБрюйна формируются деревья решений, используемые в качестве логического вывода системы.

На рисунке 6 представлен конвейер обработки данных при формировании графа знаний. Информация выбирается на основе вновь поступивших данных о треке пациента в хранилище первичной информации.

Алгоритмы обработки графа

На первом этапе из текстовой информации, введенной в систему, выделяется фактологическая часть: ключевые слова, цифровые значения, вторичная семантическая информация. Оценивается полнота и точность введенной

информации, выполняется проверка на корректность введенных данных.

По полученной информации о последовательности прецедентов одного пациента выполняется анализ и классификация вершины (прогноз предположительного диагноза). Целью такого анализа является соотнесение трека пациента с определенным заболеванием, анализируемым системой.

Далее производится анализ темпоральной информации (динамических характеристик трека), информация анализируется на противоречия, ошибки. Если анализ завершился успешно, прецеденты дополняются информацией о динамике трека, и передаются на этап кодирования.

На основе словаря уникальных кодов вершин и информации прецедентов пациента формируется уникальный код состояния пациента. Состояние пациента может быть соотнесено с




Рисунок 6 — Формирование графа знаний на основе цепочек медицинских событий.




Рисунок 7 — Процесс выработки предиктивной оценке диагноза.

уже имеющимся состоянием других пациентов, т.е. может не быть уникальным. В этом случае трек пациента считается позиционированным корректно и модель пациента готова к предиктивной оценке диагноза. Если же схожего состояния в словаре нет, то вновь полученный код добавляется в словарь.

На рисунке 7 представлен конвейер предиктивной оценки диагноза (поиска подобия на графе ДеБрюйна).

На основе словаря уникальных кодов вершин и графа знаний выполняется поиск схожих прецедентов и треков. При этом учитываются: набор значений атрибутов прецедентов и их веса, принятые в модели пациента. Веса атрибутов влияют на результаты поиска, и могут меняться в течение времени жизни модели пациента. На основе поиска схожих прецедентов формируются вероятные треки, схожие с треком пациента. Далее происходит выбор группы треков, имеющих наибольшую меру схожести. На основе найденных схожих треков формируется модель

пациента, которая записывается в хранилище моделей. Результат поиска схожих прецедентов, треков и возможных диагнозов записываются в хранилище результатов логического вывода.

Пример программной реализации обработки графа

Результатом работы классификатора графовой нейронной сети является принадлежность узла (в исследуемом случае это пациент) к множеству переменных статуса `Healthy_Status` — на выходном слое формируется функция $\log(\text{softmax}(x))$, что дает возможность получить меру принадлежности с помощью `torch.exp(output)` к классам 0 или 1. Этот прием используется для того, чтобы получить стабильный результат классификации. Архитектура сети представлена на рисунке 8.

Пример реализации графовой нейронной модели показал точность 97% (acc: 0.9797, val_acc: 0.9727). Данные были разбиты на тренировочную, тестовую и валидационную выборку.

```
class GCN(torch.nn.Module):
    def __init__(self, dim_in, dim_h, dim_out):
        super().__init__()
        self.gcn1 = GCNConv(dim_in, dim_h)
        self.gcn2 = GCNConv(dim_h, dim_out)
        self.optimizer = torch.optim.Adam(self.parameters(), lr=0.01,
                                           weight_decay=5e-4)

    def forward(self, x, edge_index):
        h = F.dropout(x, p=0.5, training=self.training)
        h = self.gcn1(h, edge_index)
        h = torch.relu(h)
        h = F.dropout(h, p=0.5, training=self.training)
        h = self.gcn2(h, edge_index)
        return h, F.log_softmax(h, dim=1)
```

Рисунок 8 — Архитектура сети.




Рисунок 9 — Характеристики точности обучения нейросети MLP (multilayer perceptron) и графовой нейронной сети GNN с параметрами epoch = 50, learning_rate = 0,01, dropout_rate = 0,5.

Анализ рисунка 9 показывает, что увеличение количества эпох не имеет смысла. Структура данных и архитектура графовых сверточных слоёв такова, что прирост точности не обеспечивается. В сравнении с решением задачи с использованием классической полносвязной нейронной сети MLP продемонстрирована точность 83%.

Для объединения подсистем обработки графов в единый комплекс предусмотрены сетевые интерфейсы: на уровне узла применяется подсистема сетевого взаимодействия узлов; на уровне ядер GPC применяется кольцевая сеть связи ядер.

На основании структурно-функциональной схемы (рисунок 5) и результатов программного

моделирования создана архитектура прозрачного ИИ, предназначенная для решения медицинских задач (см. рисунок 10).

Разработанный комплекс Тераграф (хранилище данных на рисунке 10) предназначен для хранения и обработки графов сверхбольшой размерности и применяется для моделирования биологических систем, анализа потоков мультимодальных данных в режиме реального времени, хранения знаний в системах ИИ, создания интеллектуальных систем поддержки принятия врачебных решений. Он способен обрабатывать графы сверхбольшой размерности до 10^{12} (одного триллиона) вершин и $2 \cdot 10^{12}$ ребер.

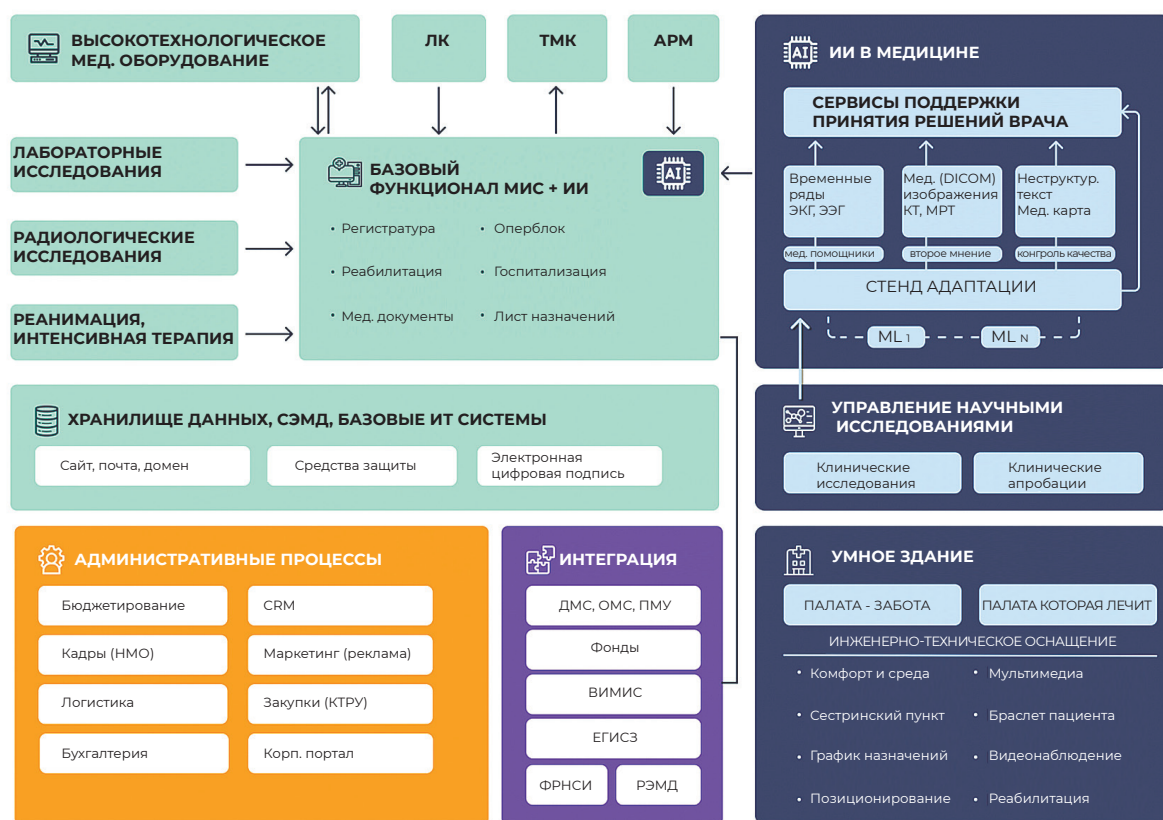


Рисунок 10 — Архитектура информационной системы медицинского назначения в составе с ИИ: ML — machine learning алгоритмы, ЛК — личный кабинет, ТМК — телемедицинская консультация, АРМ — автоматизированное рабочее место, МИС — медицинская информационная система, ЭКГ — электрокардиограмма, ЭЭГ — электроэнцефалограмма, КТ/МРТ — компьютерная/магниторезонансная томограмма, КТРУ — каталог товаров работ и услуг, CRM — customer relationship management, ДМС/ОМС — добровольное/обязательное медицинское страхование, ПМУ — платные медицинские услуги, ВИМИС — вертикально интегрированные медицинские системы, ЕГИСЗ — единая государственная информационная система здравоохранения, ФРНСИ — федеральный реестр нормативно-справочной информации, РЭМД — реестр электронных медицинских документов, НМО — непрерывное медицинское образование.

Результаты работы алгоритма и архитектурный подход (рисунок 10, см. стенд адаптации с ML_i — i-я модель машинного обучения) показывают возможность типологически наблюдать как разделяются классы в датасете (задача классификации узлов для предиктивной оценки диагноза *Healthy Status*: пациент или условно здоровый). На основе этого алгоритма в [12] реализовано автоматическое обнаружение аритмии по ЭКГ. Без применения графового подхода пришлось

бы решать сложную задачу расчета корреляции между несколькими отведениями ЭКГ или рассчитывать обширный объем признаков, что не требуется в данном алгоритме.

ОБСУЖДЕНИЕ

Графовые нейронные модели основаны на представлении исходных данных с минимальными потерями атрибутивной и ассоциативной информации (node_feature). Структура графа

знаний формируется на основе модели графа произвольного вида (ориентированный, гиперграф) в зависимости от требований к модели. Ребра и вершины графа знаний обладают набором атрибутов, которые могут быть проанализированы при анализе, и позволяют прямым образом представить информацию темпорального характера и причинно-следственных связей.

Представленный код реализует преобразование дублированных медицинских записей в графовую структуру для анализа временных паттернов и семантических взаимосвязей. Модель строится на основе DataFrame duplicated_rows, содержащего повторяющиеся записи пациентов, и преобразует их в ориентированный граф с узлами двух типов. Узлы-источники (source) представляют уникальные идентификаторы пациентов (subject_id), а узлы-цели (target) соответствуют токенизированным текстовым описаниям медицинских отчетов (report). Каждое ребро графа характеризуется временной меткой (edge_key) — датой проведения ЭЭГ-исследования (Date), весовым коэффициентом (weight) на основе текстового отчета и статусом здоровья пациента (Healthy_Status).

Особенностью данной модели является интеграция разнородных медицинских данных в единую графовую структуру. Временные метки позволяют анализировать последовательность и частоту медицинских обследований, текстовые описания дают возможность семантического анализа изменений в состоянии пациента, а статус здоровья служит количественным показателем для оценки динамики. Такое представление данных особенно ценно для выявления скрытых временных паттернов у пациентов с повторными обследованиями, анализа причин дублирования записей и обнаружения потенциальных ошибок ввода данных.

Прогнозирование развития трека пациента на основе максимального подобию. На основе автоматизированного поиска прецедентов выполняется поиск наиболее схожего трека и прецедентов, хранимых в графе знаний. Предиктивный анализ развития трека пациента и выдача результата в виде одного трека или дерева решений выполняется на основе существующей в систем модели пациента в виде графа знаний [13]. На основе индивидуального трека пациента происходит поиск схожих прецедентов и

треков и делается вывод о текущем состоянии модели пациента в основном графе знаний. Полученный результат (индекс наиболее схожей вершины графа знаний), процесс его формирования и мера схожести записываются в хранилище результатов логического вывода.

Важным аспектом работы данной платформы (фреймворка) является реализация задачи поддержания высокой степени достоверности и надежности выводов, полученных с помощью ИИ, для прозрачного взаимодействия врача и ИИ, а также общего повышения эффективности принятия врачебных решений в кардиологии на основании ИИ [14].

ЗАКЛЮЧЕНИЕ

Ключевыми вызовами и наиболее актуальными направлениями для дальнейших исследований являются вопросы доверия к цифровой медицине в целом и системам ИИ в частности, нормативное и техническое регулирование, решение проблем асимметрии между ценностями алгоритмов машинного обучения и размеченных массивов данных, использованных при их разработке, повышение точности работы моделей машинного обучения, вопросы биоэтической и объяснимости работы ИИ, а также поддержка профильных междисциплинарных образовательных программ на стыке информатики и медицины и технологических компаний в области цифровой медицины.

Целесообразно выделить два вектора развития представленной модели: 1) разработка подсистемы предиктивной аналитики для поддержки принятия решений по обеспечению возможности раннего выявления патологических состояний или отклонений от «нормы здоровья» у пациентов для превентивного лечения на ранних стадиях развития болезни; 2) разработка подсистемы сбора и глубокого анализа медицинских данных для детализации и расширенного поиска в пределах заданной нозологии. В дальнейшей работе видится необходимым учитывать субъективные особенности пациента, строить индивидуальную модель динамики состояния пациента и на ее основе делать прогноз.

Графовая нейронная модель в архитектуре прозрачного ИИ позволяет проводить комплексный анализ, включая выявление временных кластеров дублированных исследований,

изучение взаимосвязи между частотой обследований и статусом здоровья, а также сопоставление содержания текстовых отчетов с динамикой состояния пациента. Преимуществом подхода является сохранение полного временного контекста записей при одновременном

учете как структурированных (даты, статусы), так и неструктурированных (тексты отчетов) данных.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

ЛИТЕРАТУРА/REFERENCES

1. Карпов О.Э., Андриков Д.А., Максименко В.А., Храмов А.Е. Прозрачный искусственный интеллект для медицины // Врач и информационные технологии. — 2022. — №2. — С.4-11. [Karpov OE, Andrikov DA, Maksimenko VA, Hramov AE. Prozrachnyĭ iskusstvennyĭ intellekt dlya mediciny. Vrach i informacionnye tekhnologii. 2022; 2: 4-11. (In Russ.)]
2. Карпов О.Э., Храмов А.Е. Прогностическая медицина // Врач и информационные технологии. — 2021. — №3. — С.20. [Karpov OE, Hramov AE. Prognosticheskaya medicina. Vrach i informacionnye tekhnologii. 2021; 3: 20. (In Russ.)]
3. Шарова Д.Е., Михайлова А.А., Гусев А.В., Гарбук С.В., Владимирский А.В., Васильев Ю.А. Анализ мирового опыта в регулировании использования медицинских данных для целей создания систем искусственного интеллекта на основе машинного обучения // Врач и информационные технологии. — 2022. — №4. — С.28-39. [SHarova DE, Mihajlova AA, Gusev AV, Garbuk SV, Vladzimirskij AV, Vasil'ev YUA. Analiz mirovogo opyta v regulirovanii ispol'zovaniya medicinskih dannyh dlya celej sozdaniya sistem iskusstvennogo intellekta na osnove mashinnogo obucheniya. Vrach i informacionnye tekhnologii. 2022; 4: 28-39. (In Russ.)]
4. Карпов О.Э., Храмов А.Е. Информационные технологии, вычислительные системы и искусственный интеллект в медицине. М.: ДПК Пресс, 2022. [Karpov O. E., Hramov A.E. Informacionnye tekhnologii, vychislitel'nye sistemy i iskusstvennyĭ intellekt v medicine. M.:DPK Press, 2022. (In Russ.)]
5. Васильев Ю.А. и др. Подготовка набора данных для обучения и тестирования программного обеспечения на основе технологии искусственного интеллекта: Учебное пособие. М.: Издательские решения, 2024. — 140 с. [Vasil'ev YUA, et al. Podgotovka nabora dannyh dlya obucheniya i testirovaniya programmnoĭ obespecheniya na osnove tekhnologii iskusstvennogo intellekta: Uchebnoe posobie. M.: Izdatel'skie resheniya, 2024. 140 p. (In Russ.)]
6. Khorev VS, et al. Disruptions in segregation mechanisms in fmri-based brain functional network predict the major depressive disorder condition. Chaos, Solitons & Fractals. 2024; 188: 115566.
7. Кучин А.С., Грубов В.В., Максименко В.А., Утяшев Н.П. Автоматизированное рабочее место врача эпилептолога с возможностью автоматического поиска приступов эпилепсии // Врач и информационные технологии. — 2021. — № 3. — С.62-73. [Kuchin AS, Grubov VV, Maksimenko VA, Utyashev NP. Avtomatizirovannoe rabochee mesto vracha epileptologa s vozmozhnost'yu avtomaticheskogo poiska pristupov epilepsii. Vrach i informacionnye tekhnologii. 2021; 3: 62-73. (In Russ.)]
8. Grubov VV, Nazarikov SI, Kurkin SA, Utyashev NP, et al. Two-stage approach with combination of outlier detection method and deep learning enhances automatic epileptic seizure detection. IEEE Access. 2024; 12: 122168-122182.
9. Wang J, Yang J, Deng J, Gunes H, Song S. Graph in Graph Neural Network. 2024. doi: 10.48550/arXiv.2407.00696.
10. Goldberger A, Amaral L, Glas L, Hausdorff J. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. Circulation [Online]. 2000; 101(23): e215-e220.
11. Gow B, Pollard T, Nathanson LA, Johnson A, Horng S. MIMIC-IV-ECG: Diagnostic Electrocardiogram Matched Subset (version 1.0). PhysioNet. 2023. doi: 10.13026/4nqg-sb35.
12. Zhong M, Li F, Chen W. Automatic arrhythmia detection with multi-lead ECG signals based on heterogeneous graph attention networks. Mathematical biosciences and engineering: MBE. 2022; 12(19): 12448-12471.
13. Brody S, Alon U, Yahav E. How Attentive are Graph Attention Networks?. 2021. doi: 10.48550/arXiv.2105.14491.
14. Kamyar Z, Marco G. Graph Neural Networks for Topological Feature Extraction in ECG Classification. Springer Nature Singapore. Singapore, 2023. P.17-27.