

## Применение методов радиомики для формирования признакового пространства в задаче распознавания церебральных аневризм

А. С. Кружалов\*, А. Ю. Филиппович

ФГАОУ ВО «Московский политехнический университет», г. Москва, Российская Федерация  
Адрес: 107023, Российская Федерация, г. Москва, ул. Б. Семёновская, д. 38

\* alexkruzhalov@gmail.com

### Аннотация

В работе проводится исследование эффективности применения методов радиомики для извлечения признаков из медицинских изображений при решении задачи распознавания церебральных аневризм с помощью графовой нейронной сети. Построение графовой модели сосудистой сети на основе результатов ангиографии сосудов головного мозга позволяет перейти от исходного изображения (упорядоченной последовательности значений вокселей) к более структурированному представлению исходных данных, состоящему из набора локальных дескрипторов узлов и связей между ними. Такое представление отражает наиболее значимые черты распознаваемых объектов и позволяет существенно сократить объём обрабатываемых данных. В связи с этим одним из ключевых аспектов успешного решения задачи распознавания церебральных аневризм на основе графовой модели сосудистой сети является формирование информативного признакового описания для узлов графа. В данной работе признаковое описание узлов графа соответствует биомаркерам изображений – количественным показателям, характеризующим различные патологические изменения, – полученным при помощи методов радиомики. В качестве алгоритма распознавания аневризм используется графовая нейронная сеть. В работе рассматриваются характеристики формы выделенных областей изображений, гистограммные и текстурные признаки, а также некоторые другие характеристики. Для выявления наиболее информативных признаков был проведён ряд вычислительных экспериментов с использованием различных наборов признаков. На основе статистического анализа результатов экспериментов был сделан вывод о том, что наибольшая часть значимой для распознавания церебральных аневризм информации содержится в характеристиках формы выделенных на изображении областей, а также в гистограммных признаках. Однако, также результаты экспериментов показали, что построенное признаковое описание недостаточно для точного распознавания церебральных аневризм, и оно требует расширения за счёт введения новых более сложных показателей.

**Ключевые слова:** радиомика, нейронная сеть, граф, распознавание образов, медицинские изображения, церебральные аневризмы

**Конфликт интересов:** авторы заявляют об отсутствии конфликта интересов.

**Для цитирования:** Кружалов А. С., Филиппович А. Ю. Применение методов радиомики для формирования признакового пространства в задаче распознавания церебральных аневризм // Современные информационные технологии и ИТ-образование. 2022. Т. 18, № 3. С. 608-616. doi: <https://doi.org/10.25559/SITITO.18.202203.608-616>

© Кружалов А. С., Филиппович А. Ю., 2022



Контент доступен под лицензией Creative Commons Attribution 4.0 License.  
The content is available under Creative Commons Attribution 4.0 License.



## Application of Radiomics Methods for the Formation of a Feature Space in the Problem of Recognition of Cerebral Aneurysms

A. S. Kruzhalov\*, A. Yu. Philippovich

Moscow Polytechnic University, Moscow, Russian Federation

Address: 38 Bolshaya Semyonovskaya St., Moscow 107023, Russian Federation

\* alexkruzhalov@gmail.com

### Abstract

The paper investigates the effectiveness of using radiomics methods to extract features from medical images when solving the problem of recognizing cerebral aneurysms using a graph neural network. The construction of a graph model of the vascular network based on the results of angiography of cerebral vessels allows you to move from the original image (an ordered sequence of voxel values) to a more structured representation of the original data, consisting of a set of local node descriptors and connections between them. This representation reflects the most significant features of the recognized objects and allows you to significantly reduce the amount of processed data. In this regard, one of the key aspects of successfully solving the problem of recognizing cerebral aneurysms based on a graph model of the vascular network is the formation of an informative feature description for graph nodes. In this paper, the characteristic description of graph nodes corresponds to image biomarkers – quantitative indicators characterizing various pathological changes – obtained using radiomics methods. A graph neural network is used as an algorithm for recognizing aneurysms. The paper considers the shape characteristics of the selected image areas, histogram and texture features, as well as some other characteristics. To identify the most informative features, a number of computational experiments were conducted using various sets of features. Based on the statistical analysis of the experimental results, it was concluded that the largest part of the information significant for the recognition of cerebral aneurysms is contained in the shape characteristics of the areas highlighted in the image, as well as in histogram features. However, the experimental results also showed that the constructed feature description is not sufficient for accurate recognition of cerebral aneurysms, and it requires expansion due to the introduction of new more complex indicators.

**Keywords:** radiomics, neural network, graph, pattern recognition, medical imaging, cerebral aneurysms

**Conflict of interests:** The authors declare no conflict of interest.

**For citation:** Kruzhalov A.S., Philippovich A.Yu. Application of Radiomics Methods for the Formation of a Feature Space in the Problem of Recognition of Cerebral Aneurysms. *Modern Information Technologies and IT-Education*. 2022;18(3):608-616. doi: <https://doi.org/10.25559/SITITO.18.202203.608-616>



## Введение

В последние годы показатели смертности при цереброваскулярных заболеваниях в Российской Федерации показывают устойчивый тренд на снижение<sup>1</sup>, однако, уровень смертности всё ещё достаточно высокий – 180,5 случаев на 100 тыс. населения [1]. Частой причиной геморрагического инсульта является разрыв аневризмы сосудов головного мозга, поэтому задача своевременной диагностики и лечения церебральных аневризм в контексте снижения показателей смертности от цереброваскулярных заболеваний играет важную роль.

Своевременная диагностика церебральных аневризм возможна благодаря применению современных методов лучевой диагностики: компьютерной томографии, магнитно-резонансной томографии, ротационной ангиографии. Перечисленные методы медицинской визуализации позволяют получить трёхмерное изображение сосудов головного мозга пациента, на основании чего врач может определить наличие аневризмы, оценить её размеры и риск разрыва.

В условиях роста количества проводимых исследований (в период с 2007 по 2017 г. хирургическая активность при аневризмах головного мозга в РФ выросла в 6 раз [1]) для повышения эффективности работы специалистов на сегодняшний день в клиническую практику широко внедряются системы компьютерной автоматизированной диагностики. Для автоматизации анализа медицинских изображений в таких системах используются современные методы распознавания образов (в частности, широко используются свёрточные нейронные сети [2-10]). Особенность задачи распознавания церебральных аневризм состоит в необходимости учитывать пространственную (трёхмерную) структуру анализируемых изображений [11]. При использовании свёрточных нейронных сетей это приводит к существенному росту необходимого объёма оперативной памяти (или памяти графического процессора), что вынуждает исследователей разделять исходные изображения на фрагменты и работать с ними по отдельности [3]. Это, в свою очередь, приводит к ограничению учитываемого окружающего контекста при работе с конкретным фрагментом изображения и может приводить к снижению точности распознавания.

Информативным признаком для распознавания церебральных аневризм является структура сосудистой сети. Так, например, известно, что чаще всего аневризмы возникают в местах изгибов несущих артерий и местах отхождения крупных ветвей сосудов<sup>2</sup>. Для представления сосудистой сети можно использовать графовые модели, которые представляют собой так называемое *символьное представление*<sup>3</sup> сосудистой сети [12, 13].

Для решения задач распознавания образов на основе данных, представленных в виде графов, существует специальный класс

нейронных сетей – графовые нейронные сети [14, 15]. Основной операцией в графовых нейронных сетях является графовая свёртка, которая позволяет преобразовывать представление вершин графа с учётом окружающего их контекста (смежных вершин). Применение графовой свёртки позволяет учесть связность вершин графа при обучении нейронной сети, а также требует гораздо меньше вычислительных ресурсов по сравнению со свёрточными сетями, так как узлы графа, как правило, имеют достаточно «компактное» признаковое описание.

Формирование информативного с точки зрения решаемой задачи признакового описания для узлов графа играет важную роль. При построении графовой модели по изображению признаки строятся на основе локальных характеристик фрагмента изображения, соответствующего конкретному узлу. В случае медицинских изображений в качестве признаков используются биомаркеры изображений – количественные показатели, характеризующие различные патологические изменения. Такие биомаркеры могут быть получены путём применения методов радиомики [16, 17], которые позволяют извлечь из изображения характеристики, описывающие патологические особенности изображённых на нём тканей.

## Цель исследования

Как показывают результаты предыдущих исследований, графовые модели могут быть эффективны при решении задачи распознавания церебральных аневризм [4, 18]. Также имеются данные о положительном опыте применения радиомики для решения задачи прогнозирования риска разрыва [19, 20] и «стабильности» аневризм [21]. Однако, авторы не нашли в литературе упоминаний о совместном применении этих двух подходов для решения рассматриваемой задачи. В связи с этим **цель данной работы** – исследовать эффективность применения методов радиомики для извлечения биомаркеров изображений при решении задачи распознавания церебральных аневризм с помощью графовой нейронной сети.

## Материалы и методы исследования

В работе используются данные, опубликованные в рамках соревнования Cerebral Aneurysm Detection (CADA)<sup>4</sup>. В этом наборе данных представлено 110 изображений (результатов ротационной ангиографии). Данные были получены при помощи ангиографической системы AXIOM Artis типа «С-дуги» (англ. C-arm). При реконструкции области интереса, выбранной нейрохирургом, было сгенерировано 220 срезов с матрицей размером 256 × 256 вокселей. Размер вокселя составил примерно 0.5 мм. Для каждого изображения в наборе данных имеется маска сегментации, которая определяет положение и границы аневризмы.

<sup>1</sup> Динамика смертности от болезней системы кровообращения в Москве 1989-2017 / Е. И. Аксенова [и др.]. М. : ГБУ «НИИОЗММ ДЗМ», 2019. 16 с. URL: <https://nioz.ru/upload/iblock/a9f/a9f636aa2d643f44fb6566af4f31cacb.pdf> (дата обращения: 29.08.2022).

<sup>2</sup> Берестов В. В. Эмболизация церебральных аневризм в остром периоде геморрагического инсульта : дис. ... канд. мед. наук. Новосибирск : ФГБУ «ННИИТО им. Я.Л. Чивьяна» Минздрава России, 2021. 138 с.

<sup>3</sup> Li F. Segmentation and Symbolic Representation of Cerebral Vascular Network: applied to modelize ArterioVenous Malformations : PhD thesis. University of Paris Est Créteil, 2016. 165 p.

<sup>4</sup> CADA – Cerebral Aneurysm Detection [Электронный ресурс] // Grand Challenge, 2022. URL: <https://cada.grand-challenge.org> (дата обращения: 29.08.2022).



Первый шаг при построении графовой модели сосудистой сети – это выделение (сегментация) сосудов на изображении. Так как исследование проводилось с введением рентген-контрастного вещества, задача выделения сосудистой сети может быть решена при помощи пороговых методов сегментации. В частности, в данной работе для этих целей используется метод треугольника (англ. triangle thresholding) [22] с последующим выделением наибольшей связной области.

После выделения на изображении области, соответствующей сосудам, необходимо найти скелет полученной фигуры, на основе которого впоследствии можно получить граф. Под скелетом понимается множество точек, равноудалённых от границ фигуры. В данной работе для получения скелета был использован алгоритм Lee [23]. Он относится к дискретным алгоритмам скелетизации, в основе которых лежит морфологическая операция истончения (англ. thinning).

Для получения графа на основе скелета необходимо решить задачу классификации точек скелета. Каждая точка должна быть отнесена к одной из двух категорий: узловая или промежуточная. Узловые точки соответствуют вершинам графа, а промежуточные – сегментам, соединяющим узловые вершины и образующим рёбра графа. Решение об отнесении каждой точки к определённому классу принимается на основе анализа окрестности данной точки.

Так как задача распознавания церебральных аневризм на основе графовой модели сосудистой сети сводится к решению задачи классификации вершин графа, для каждой вершины была определена метка класса, показывающая, относится ли данная вершина к аневризму. Метки класса были вычислены на основе координат вершин в исходном изображении и масок сегментации областей интереса (аневризм).

При построении графа нужно иметь в виду, что большинство дискретных алгоритмов скелетизации чувствительны к шумовым эффектам, которые могут присутствовать на изображениях, вследствие чего могут возникать искажения скелета. Поэтому в данной работе при построении графа из него были удалены вершины степени 1, длина единственного ребра которых была меньше 5 (длина была вычислена по евклидовой метрике на основе координат вершин графа на исходном изображении), так как эти вершины рассматривались как шумовые.

Для решения задачи классификации вершин графа необходимо каждой вершине сопоставить признаковое описание, характеризующее локальные особенности фрагмента изображения, расположенного в некоторой окрестности рассматриваемой вершины. В данной работе в качестве признаков были использованы биомаркеры изображений, полученные при помощи методов радиомики [16]. Эти методы позволяют получить количественные характеристики изображения, которые можно разделить на 7 групп: характеристики формы (16 признаков), характеристики первого порядка (гистограммные) (19 признаков), характеристики второго порядка (текстурные) (24 признака), Gray Level Dependence Matrix (14 признаков), Gray Level Run Length Matrix (16 признаков), Gray Level Size Zone (16 признаков), Neighbouring Gray Tone Difference Matrix (5 признаков). Полный перечень вычисляемых признаков приведён в

документации к программному пакету PyRadiomics<sup>5</sup>. Перечисленные показатели были вычислены на основе куба с длиной стороны 65 с центром в обрабатываемом узле графа. В рамках экспериментов было проведено сравнение эффективности использования для обучения нейронной сети различных дескрипторов вершин: координат (3 признака), характеристик формы и гистограммных признаков (35 признаков с учётом положений вершин), полного набора приведённых выше дескрипторов (110 признаков), а также всех дескрипторов кроме характеристик формы и гистограммных признаков (78 признаков).

Для предварительной оценки информативности сформированного признакового описания были использованы методы визуализации многомерных данных: метод главных компонент и t-SNE. Они позволяют оценить распределение данных разных классов в признаковом пространстве.

Как уже было упомянуто ранее, задача распознавания церебральных аневризм на основе графовой модели сосудистой сети сводится к решению задачи классификации вершин графа. Для решения данной задачи была использована графовая нейронная сеть.

Каждый слой графовой нейронной сети вычисляет новое представление вершин. Новое представление для каждой вершины вычисляется на основе её текущего представления, а также на основе соседних вершин (окрестности). В общем виде формулу для обновления представления можно записать следующим образом

$$\mathbf{h}_q^{(l)} = \text{UPDATE}^{(l)} \left( \mathbf{h}_q^{(l-1)}, \text{AGG}^{(l)}(\{\mathbf{h}_u^{(l-1)}\}_{u \in N(q)}) \right),$$

где  $q$  – номер вершины,  $l$  – номер слоя,  $\mathbf{h}_q^{(l)}$  – представление вершины  $q$  на слое  $l$ ,  $\text{UPDATE}^{(l)}$  – функция обновления состояния о вершине на основе текущего состояния и агрегированного представления смежных вершин,  $\text{AGG}^{(l)}$  – функция агрегирования (должна быть инвариантна к преобразованию перестановки),  $N(q)$  – окрестность вершины  $q$  (множество вершин, смежных с  $q$ ).

Приведённая выше формула основана на приёме распространения сообщений (англ. message passing), широко применяющемся при анализе графов. В зависимости от выбора конкретных функций  $\text{UPDATE}^{(l)}$  и  $\text{AGG}^{(l)}$  можно получить различные модели распространения сообщений. В данной работе предлагается использовать графовые свёртки, предложенные в работе [24]. В матричном виде формула для обновления состояний выглядит следующим образом

$$\mathbf{X}' = \widehat{\mathbf{D}}^{-1/2} \widehat{\mathbf{A}} \widehat{\mathbf{D}}^{-1/2} \mathbf{X} \mathbf{W},$$

где  $\widehat{\mathbf{A}} = \mathbf{A} + \mathbf{I}$  (в матрицу смежности добавляются петли),  $\mathbf{D}$  – диагональная матрица степеней вершин ( $\hat{d}_{ii} = \sum_j \hat{A}_{ij}$ ),  $\mathbf{X}$  – матрица вершины-признаки,  $\mathbf{W}$  – матрица настраиваемых параметров преобразования, которая задаёт размерность выходного представления.

В качестве целевой функции для обучения нейронных сетей была использована перекрёстная энтропия, которая задаётся формулой

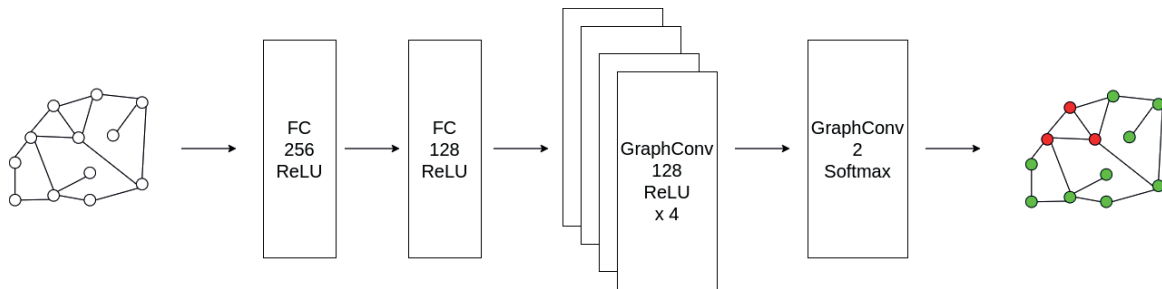
<sup>5</sup> PyRadiomics Documentation [Электронный ресурс]. URL: <https://pyradiomics.readthedocs.io/en/latest> (дата обращения: 29.08.2022).



$$L_{BCE}(\mathbf{p}) = - \sum_{i=1}^n [w_1 \cdot y_i \cdot \log \hat{y}_i + w_0 \cdot (1 - y_i) \cdot \log(1 - \hat{y}_i)],$$

где  $n$  — количество объектов (вершин) в выборке,  $y_i$  — фактическая метка класса  $i$ -й вершины,  $\hat{y}_i$  — предсказанная метка класса  $i$ -й вершины,  $w_0$  и  $w_1$  — весовые коэффициенты для сглаживания дисбаланса класса,  $\mathbf{p}$  — вектор параметров модели, от которых зависит целевая функция. Чтобы учесть дисбаланс классов (вершин, относящихся к аневризмам, суще-

ственно меньше), в целевую функцию были добавлены весовые коэффициенты.  $w_0$  — для класса 0 и  $w_1$  — для класса 1. Значения весовых коэффициентов были установлены обратно пропорционально частотам встречаемости соответствующих классов в тех данных, на основе которых вычисляется значение целевой функции. Для обучения нейронных сетей был использован алгоритм Adam (Adaptive moment estimation) с параметрами  $\alpha = 0,001$ ,  $\beta_1 = 0,9$ ,  $\beta_2 = 0,99$ .



Р и с. 1. Архитектура используемой нейронной сети

F i g. 1. The architecture of the used neural network

Архитектура используемой в работе нейронной сети представлена на рис. 1.


На вход нейронной сети подаётся граф сосудистой сети. В качестве первых двух слоёв нейронной сети используются полносвязные слои, содержащие 256 и 128 нейронов соответственно. Первые два слоя производят преобразование пространства признаков узлов графа без учёта информации об их связности. Затем идут 4 последовательных слоя графовых свёрток, содержащие по 128 нейронов. Выходной слой также вычисляет графовую свёртку с использованием 2-х нейронов. Графовые свёртки формируют описание вершин с учётом окружающего их контекста, а количество свёрток определяет «ширину» учитываемого контекста. Функция активации выходного слоя — Softmax, скрытых слоёв — ReLU (Rectified Linear Unit).

Для оценки качества решения задачи были использованы стандартные метрики для задачи бинарной классификации: «аккуратность», точность, полнота, F-мера. Значения метрик вычисляются для каждого графа в отдельности, а затем усредняются по выборке. Чтобы оценить статистическую значимость различий результатов, полученных в рамках проведённых экспериментов, в данной работе был использован критерий Уилкоксона.

## Результаты исследования и их обсуждение

Перед применением порогового преобразования значения интенсивностей вокселей каждого изображения были стандартизованы — приведены к нулевому среднему значению и единичному стандартному отклонению. Затем для сегментации сосудов было применено пороговое преобразование по методу треугольника (пример полученной области приведён на рис. 2 а). После этого для каждого изображения был построен граф сосудистой сети (рис. 2 б). Количество узлов в полученных графах составило в среднем 1474 ( $\pm 624$ ), количество

рёбер — 1880 ( $\pm 894$ ). В графе древовидной структуры количество рёбер должно быть равно ( $-$  количество узлов). Предполагая, что граф сосудистой сети должен иметь вид дерева, можно отметить, что полученные графы содержат в среднем 25% избыточных рёбер. Такое несоответствие можно объяснить недостатками алгоритмов сегментации и скелетизации. Однако, как видно по приведённому на рис. 2 примеру, построенная модель в целом воспроизводит основные структурные свойства сосудистой сети.



Р и с. 2. Результат применения порогового преобразования (а) и построения графа (б)

F i g. 2. The result of applying the threshold transformation (a) and constructing the graph (b)

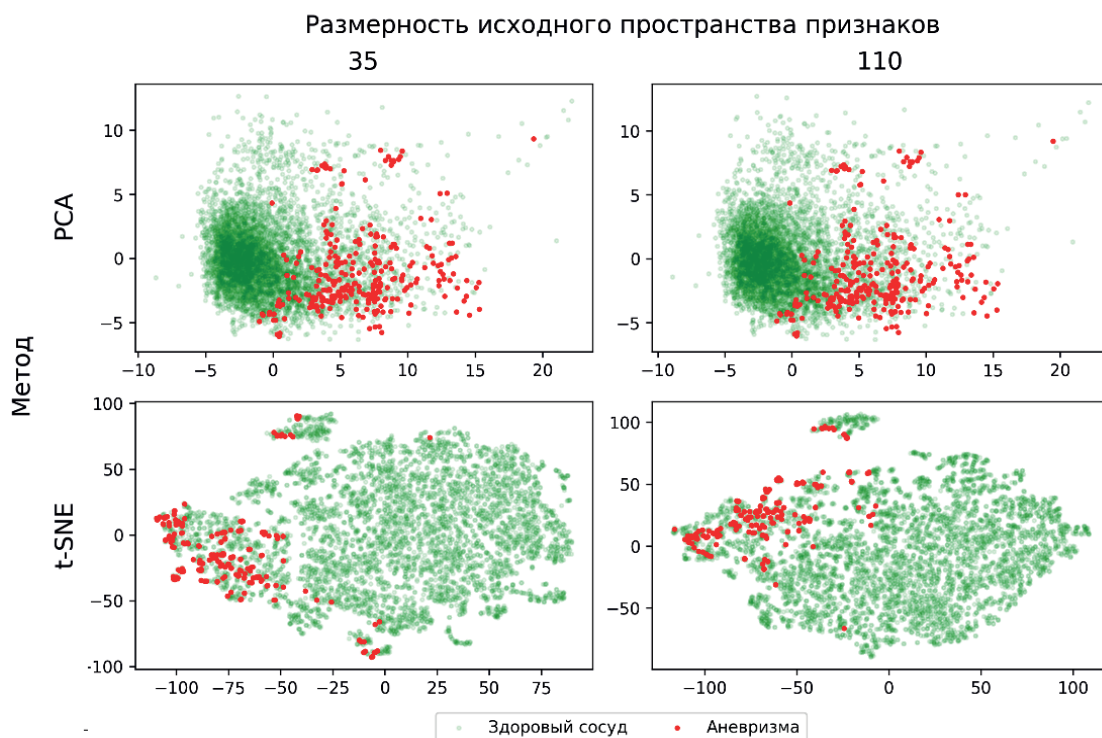
При решении задачи классификации предполагается, что объекты одного класса образуют компактно локализованные подгруппы в пространстве признаков. Чтобы в этом убедиться, были построены визуализации узлов графа на плоскости, полученные на основе их признаковых описаний при помощи метода главных компонент и алгоритма t-distributed Stochastic Neighbor Embedding (t-SNE) [25] (рис. 3). Приведённые на





рис. 3 графики были получены на основе 6027 случайно выбранных узлов различных графов (из них 287 относятся к аневризмам, 5740 – к здоровым сосудам). Всего в данных присутствует 159149 узлов. Количество данных для визуализации было ограничено из соображений ускорения вычислений. Первый столбец соответствует использованию 35 признаков

(координаты вершин, дескрипторы формы, гистограммные дескрипторы), а второй – 110 признакам (координаты вершин и все перечисленные ранее дескрипторы, полученные методом радиомики). Первая строка соответствует методу главных компонент, вторая – t-SNE.



Р и с. 3. Визуализации признакового пространства, полученные при помощи метода главных компонент и t-SNE  
F i g. 3. Feature Space Visualizations Obtained Using Principal Component Analysis and t-SNE

По приведённым графикам видно, что даже линейная проекция на плоскость главных компонент отображает общность характеристик узлов-аневризм, так как они образуют явно выраженное скопление точек на графике. При этом большая часть узлов, соответствующих здоровым сосудам (назовём их «фоновыми» узлами), находится на некотором отдалении. Метод t-SNE показал аналогичные результаты, но нелинейное преобразование позволило более полно отразить разброс положений «фоновых» узлов. Что касается различий между использованием 35 и 110 признаков, оба метода показали похожие результаты.

Для оценки эффективности построенного признакового описания для решения рассматриваемой задачи была проведена серия вычислительных экспериментов. В каждом эксперименте была обучена нейронная сеть описанной выше архитектуры. Перед обучением нейронных сетей данные были разделены на обучающую и тестовую выборки: в обучающую выборку попало 88 объектов (129885 узлов), в тестовую – 20 объектов (29264 узлов). Нейронная сеть обучалась в течение 500 эпох. Список проведённых экспериментов и полученные результаты приведены в табл. 1. Приведённые в таблице значения

метрик вычислены по тестовой выборке путём усреднения значений, полученных для каждого графа.

Т а б л и ц а 1. Результаты вычислительных экспериментов  
T a b l e 1. Results of computational experiments

№	Размерность пространства признаков	«Аккуратность» (accuracy)	Точность (precision)	Полнота (recall)	F-мера (F1-score)
1	3	0,8995	0,0317	0,7514	0,0558
2	35	0,9679	0,1284	0,5337	0,1632
3	78	0,9387	0,0490	0,7500	0,0884
4	110	0,9552	0,0843	0,6567	0,1385

Для оценки статистической значимости наблюдаемых различий по каждой метрике был использован критерий Уилкоксона с поправкой Бонферрони на множественные сравнения. Результаты множественных сравнений приведены в табл. 2. Для каждой пары выборок в таблице приведены результаты по четырём рассматриваемым метрикам в следующем порядке (слева направо сверху вниз): accuracy, precision, recall, F1-score.



Для каждой метрики приведено 3 числа: значение статистики критерия Уилкоксона ( $W$ ),  $p$ -значение до применения поправки,  $p$ -значение после применения поправки Бонферрони.  $P$ -значения, не превосходящие выбранный уровень значимости, выделены жирным шрифтом. В таблице использована цветовая ин-

дикация для обозначения статистически значимых различий: зелёным обозначены различия, статистическая значимость которых сохраняется после применения поправки, синим – те, для которых не сохраняется.

Таблица 2. Результаты попарных сравнений оценок точности работы моделей, обученных на различных наборах данных  
Table 2. The results of pairwise comparisons of estimates of the accuracy of the models trained on different data sets

	3		35		78	
35	20	20				
	0.0007, <b>0.004</b>	0.004, <b>0.026</b>				
	29	27				
	0.14, 0.83	<b>0.01</b> , 0.065				
78	34	48	3	34		
	0.006, <b>0.038</b>	0.058, 0.35	0.0002, <b>0.001</b>	<b>0.04</b> , 0.26		
	26.5	48	6.5	35		
	0.92, 1.0	0.058, 0.35	<b>0.03</b> , 0.19	<b>0.049</b> , 0.29		
110	32	43	49	37	28	53
	0.0048, <b>0.029</b>	<b>0.036</b> , 0.22	0.19, 1.0	0.33, 1.0	<b>0.007</b> , <b>0.04</b>	0.16, 0.94
	35	42	10.5	38	20	54
	0.46, 1.0	<b>0.03</b> , 0.20	0.15, 0.92	0.36, 1.0	0.44, 1.0	0.17, 1.0

При уровне значимости статистически значимые различия по доле верных ответов («аккуратности») наблюдаются между всеми парами рассматриваемых выборок кроме 35–110. Это указывает на существенно более высокую точность распознавания тех моделей, которые использовали характеристики формы и гистограммные признаки. Однако, указанная метрика не учитывает дисбаланс классов, который в данной выборке достаточно существенный. По метрике «точность» (англ. precision) статистически значимые различия наблюдаются только между парой 3–35 ( $W = 20$ ,  $p$ -value (adj) = 0,026). Это можно объяснить большим количеством ложноположительных ответов модели с 3-я признаками, так как только значений координат узла недостаточно для верного прогноза. По остальным метрикам с учётом поправки на множественные сравнения статистически значимых различий не было выявлено. Однако, учитывая, что поправка Бонферрони сильно уменьшает мощность статистической процедуры, интересно также отметить, что без использования поправки между парой выборок 35–78 наблюдаются статистически значимые различия по всем метрикам. Это говорит о существенно большей информативности радиомных признаков первого порядка и формы перед остальными признаками, анализируемыми в данной работе.

## Заключение

Результаты экспериментов показали отсутствие существенной разницы в эффективности работы нейросетевых моделей

распознавания церебральных аневризм при использовании наборов данных, состоящих из 35 и 110 радиомных признаков. При этом доля верных ответов («аккуратность») статистически значимо выше для моделей, построенных с использованием гистограммных признаков и характеристик формы, по сравнению с остальными моделями.

Исходя из полученных результатов, можно сделать вывод о том, что среди рассмотренных в данной работе признаков наибольшая часть значимой для распознавания церебральных аневризм информации содержится в характеристиках формы выделенных областей, а также в гистограммных признаках, так как добавление учёта других показателей не привело к повышению точности построенной на их основе модели, а исключение указанных признаков привело к значимому уменьшению доли верных ответов. Также этот вывод подтверждается построенными визуализациями многомерных данных (рис. 3).

Приведённые в работе результаты указывают на то, что построенное признаковое описание является недостаточным для точного распознавания церебральных аневризм: несмотря на то, что используемые признаки демонстрируют способность отделить большую часть узлов графа, соответствующих здоровым сосудам, от узлов-аневризм, тем не менее существенная часть таких «фоновых» узлов имеют характеристики, схожие с характеристиками узлов-аневризм, что делает их трудноотличимыми. Поэтому одним из главных направлений дальнейшей работы является введение новых более информативных признаков.



## References

- [1] Krylov V.V. et al. Surgical Treatment of Cerebral Aneurysms in the Russian Federation. *Burdenko's Journal of Neurosurgery*. 2018;82(6):5-14. (In Russ., abstract in Eng.) doi: <https://doi.org/10.17116/neuro2018820615>
- [2] Sichtermann T, Faron A, Sijben R, Teichert N, Freiherr J, Wiesmann M. Deep Learning-Based Detection of Intracranial Aneurysms in 3D TOF-MRA. *American Journal of Neuroradiology*. 2019;40(1):25-32. doi: <https://doi.org/10.3174/ajnr.A5911>
- [3] Shi Z. et al. A clinically applicable deep-learning model for detecting intracranial aneurysm in computed tomography angiography images. *Nature Communications*. 2020;11(1):6090. doi: <https://doi.org/10.1038/s41467-020-19527-w>
- [4] Timmins K.M., van der Schaaf I.C., Vos I., Ruigrok Y.M., Velthuis B.K., Kuijf H.J. Deep learning with vessel surface meshes for intracranial aneurysm detection. *Proceedings SPIE. Medical Imaging 2022: Computer-Aided Diagnosis*. Vol. 12033. SPIE; 2022. Article number: 120332D. doi: <https://doi.org/10.1117/12.2610745>
- [5] Park A. et al. Deep Learning-Assisted Diagnosis of Cerebral Aneurysms Using the HeadXNet Model. *JAMA Network Open*. 2019;2(6):e195600. doi: <https://doi.org/10.1001/jamanetworkopen.2019.5600>
- [6] Meng C., Yang D., Chen D. Cerebral aneurysm image segmentation based on multi-modal convolutional neural network. *Computer Methods and Programs in Biomedicine*. 2021;208:106285. doi: <https://www.doi.org/10.1016/j.cmpb.2021.106285>
- [7] Li T. et al. Segmentation Method of Cerebral Aneurysms Based on Entropy Selection Strategy. *Entropy*. 2022;24(8):1062. doi: <https://doi.org/10.3390/e24081062>
- [8] Shahzad R. et al. Fully automated detection and segmentation of intracranial aneurysms in subarachnoid hemorrhage on CTA using deep learning. *Scientific Reports*. 2020;10(1):21799. doi: <https://doi.org/10.1038/s41598-020-78384-1>
- [9] Timmins K. M. et al. Comparing methods of detecting and segmenting unruptured intracranial aneurysms on TOF-MRAS: The ADAM challenge. *Neuroimage*. 2021;238:118216. doi: <https://doi.org/10.1016/j.neuroimage.2021.118216>
- [10] Liu Y., Liu J., Yuan Y. Edge-Oriented Point-Cloud Transformer for 3D Intracranial Aneurysm Segmentation. In: Wang L., Dou Q., Fletcher P.T., Speidel S., Li S. (eds.) *Medical Image Computing and Computer Assisted Intervention – MICCAI 2022*. MICCAI 2022. Lecture Notes in Computer Science. Vol. 13435. Cham: Springer; 2022. p. 97-106. doi: [https://doi.org/10.1007/978-3-031-16443-9\\_10](https://doi.org/10.1007/978-3-031-16443-9_10)
- [11] Drees D. et al. Scalable robust graph and feature extraction for arbitrary vessel networks in large volumetric datasets. *BMC Bioinformatics*. 2021;22:346. doi: <https://doi.org/10.1186/s12859-021-04262-w>
- [12] Chenoune Y. et al. Three-dimensional segmentation and symbolic representation of cerebral vessels on 3DRA images of arteriovenous malformations. *Computers in Biology and Medicine*. 2019;115:103489. doi: <https://www.doi.org/10.1016/j.compbimed.2019.103489>
- [13] Eulzer P. et al. Vessel Maps: A Survey of Map-Like Visualizations of the Cardiovascular System. *Computer Graphics Forum*. 2022;41(3):645-673. doi: <https://doi.org/10.1111/cgf.14576>
- [14] Gori M., Monfardini G., Scarselli F. A new model for learning in graph domains. In: *Proceedings 2005 IEEE International Joint Conference on Neural Networks*. Vol. 2. Montreal, QC, Canada: IEEE Computer Society; 2005. p. 729-734. doi: <https://doi.org/10.1109/IJCNN.2005.1555942>
- [15] Cao W., Yan Z., He Z., He Z. A comprehensive survey on geometric deep learning. *IEEE Access*. 2020;8:35929-35949. doi: <https://doi.org/10.1109/ACCESS.2020.2975067>
- [16] Van Griethuysen J.J.M. et al. Computational Radiomics System to Decode the Radiographic Phenotype. *Cancer Research*. 2017;77(21):e104-e107. doi: <https://doi.org/10.1158/0008-5472.CAN-17-0339>
- [17] Scapicchio C. et al. A deep look into radiomics. *La radiologia medica*. 2021;126(10):1296-1311. doi: <https://www.doi.org/10.1007/s11547-021-01389-x>
- [18] Girardi D. et al. A skeleton-based SVM-supported cerebral aneurysm detection algorithm. In: *European Congress of Radiology-ECR 2012*. Article number: C-0361. ECR; 2012. doi: <https://www.doi.org/10.1594/ecr2012/C-0361>
- [19] Alwalid O. et al. CT Angiography-Based Radiomics for Classification of Intracranial Aneurysm Rupture. *Frontiers in Neurology*. 2021;12:619864. doi: <https://doi.org/10.3389/fneur.2021.619864>
- [20] Lauric A., Ludwig C.G., Malek A.M. Enhanced Radiomics for Prediction of Rupture Status in Cerebral Aneurysms. *World Neurosurgery*. 2022;159:8-22. doi: <https://doi.org/10.1016/j.wneu.2021.11.038>
- [21] Liu Q.L. et al. Prediction of Aneurysm Stability Using a Machine Learning Model Based on PyRadiomics-Derived Morphological Features. *Stroke*. 2019;50(9):2314-2321. doi: <https://doi.org/10.1161/STROKEAHA.119.025777>
- [22] Zack G.W., Rogers W.E., Latt S.A. Automatic measurement of sister chromatid exchange frequency. *Journal of Histochemistry & Cytochemistry*. 1977;25(7):741-753. doi: <https://doi.org/10.1177/25.7.70454>
- [23] Lee T.C., Kashyap R.L., Chu C.N. Building Skeleton Models via 3-D Medial Surface Axis Thinning Algorithms. *CVGIP: Graphical Models and Image Processing*. 1994;56(6):462-478. doi: <https://doi.org/10.1006/cgip.1994.1042>
- [24] Kipf T.N., Welling M. Semi-Supervised Classification with Graph Convolutional Networks. In: *Proceedings of the 5th International Conference on Learning Representations (ICLR 2017)*. Toulon, France; 2017. p. 1-14. Available at: <https://openreview.net/forum?id=SJU4ayYgl> (accessed 29.08.2022).





- [25] Van der Maaten L., Hinton G. Visualizing Data using t-SNE. *Journal of Machine Learning Research*. 2008;9(86):2579-2605. Available at: <https://www.jmlr.org/papers/v9/vandermaaten08a.html> (accessed 29.08.2022).

*Поступила 29.08.2022; одобрена после рецензирования 03.10.2022; принята к публикации 11.10.2022.  
Submitted 29.08.2022; approved after reviewing 03.10.2022; accepted for publication 11.10.2022.*

#### Об авторах:

**Кружалов Алексей Сергеевич**, аспирант, преподаватель кафедры инфокогнитивных технологий, ФГАОУ ВО «Московский политехнический университет» (107023, Российская Федерация, г. Москва, ул. Б. Семёновская, д. 38), **ORCID: <https://orcid.org/0000-0003-0004-2334>**, alexkruzhalov@gmail.com

**Филиппович Андрей Юрьевич**, профессор кафедры инфокогнитивных технологий, ФГАОУ ВО «Московский политехнический университет» (107023, Российская Федерация, г. Москва, ул. Б. Семёновская, д. 38), кандидат технических наук, доцент, **ORCID: <https://orcid.org/0000-0002-8291-2411>**, a.y.philippovich@mospolytech.ru

*Все авторы прочитали и одобрили окончательный вариант рукописи.*

#### About the authors:

**Alexey S. Kruzhalov**, Postgraduate Student, Lecturer at the Chair of Infocognitive Technologies, Moscow Polytechnic University (38 Bolshaya Semyonovskaya St., Moscow 107023, Russian Federation), **ORCID: <https://orcid.org/0000-0003-0004-2334>**, alexkruzhalov@gmail.com

**Andrey Yu. Philippovich**, Professor of the Chair of Infocognitive Technologies, Moscow Polytechnic University (38 Bolshaya Semyonovskaya St., Moscow 107023, Russian Federation), Cand.Sci. (Eng.), Associate Professor, **ORCID: <https://orcid.org/0000-0002-8291-2411>**, a.y.philippovich@mospolytech.ru

*All authors have read and approved the final manuscript.*

