

УДК 004.852

DOI: [10.26102/2310-6018/2023.41.2.017](https://doi.org/10.26102/2310-6018/2023.41.2.017)

## Методика обучения свёрточной нейронной сети по фрагментам медицинских изображений в задаче распознавания церебральных аневризм

А.С. Кружалов✉

*Московский политехнический университет, Москва, Российская Федерация*  
*[alexkruzhhalov@gmail.com](mailto:alexkruzhhalov@gmail.com)*

**Резюме.** На сегодняшний день интеллектуальные системы находят все более широкое применение в области медицины. Особенно актуальной является задача разработки интеллектуальных систем компьютерной автоматизированной диагностики (КАД), которые могут быть использованы как вспомогательный инструмент, позволяющий повысить эффективность работы специалиста в условиях постоянного роста объема медицинских данных, требующих анализа и обработки. Одной из важных составных частей современных систем КАД является модуль распознавания патологических изменений на медицинских изображениях. В работе рассматривается задача обучения свёрточной нейронной сети распознаванию аневризм сосудов головного мозга. Предлагается архитектура полностью свёрточной нейронной сети на базе архитектуры UNet, методика предварительной обработки данных, методика построения «бесшовного» прогноза на основе разделения исходного изображения на набор пересекающихся фрагментов. Проводится исследование влияния размера используемых для обучения фрагментов изображений на эффективность обучения нейронной сети. На основе статистического анализа результатов проведенных вычислительных экспериментов был сделан вывод, что размер фрагмента не является определяющим параметром, так как при его увеличении не наблюдается рост точности распознавания. При этом эксперименты показали, что увеличение размера пакета обучающих примеров при фиксации остальных параметров на прежнем уровне позволяет существенно повысить точность распознавания.

**Ключевые слова:** сверточная нейронная сеть, распознавание образов, медицинские изображения, церебральная аневризма, система компьютерной автоматизированной диагностики.

**Для цитирования:** Кружалов А.С. Методика обучения свёрточной нейронной сети по фрагментам медицинских изображений в задаче распознавания церебральных аневризм. *Моделирование, оптимизация и информационные технологии.* 2023;11(2). URL: <https://moitvvt.ru/journal/pdf?id=1341> DOI: 10.26102/2310-6018/2023.41.2.017

## Patch-based training of a convolutional neural network in the problem of cerebral aneurysms recognition

A.S. Kruzhhalov✉

*Moscow Polytechnic University, Moscow, the Russian Federation*  
*[alexkruzhhalov@gmail.com](mailto:alexkruzhhalov@gmail.com)*

**Abstract.** Nowadays, intelligent systems are widely used in the field of medicine. Especially relevant is the problem of developing intelligent computer-aided diagnostics (CAD) systems which can be used as an auxiliary tool to improve specialist's efficiency in the context of the growing volume of medical data requiring analysis and processing. One of the important components of modern CAD systems is the module for recognizing pathological changes in medical images. The paper considers the problem of training a convolutional neural network to recognize cerebral vascular aneurysms. The architecture of a fully convolutional neural network based on the UNet architecture, a data preprocessing technique, a

technique for constructing a seamless prediction based on the separation of the original image into a set of intersecting fragments are proposed. The influence of the size of image fragments used for training on the effectiveness of neural network training was investigated. Drawing on the statistical analysis of the results of the conducted computational experiments, it was concluded that the size of the fragment is not a determining parameter since no increase in recognition accuracy is observed with its increase. At the same time, experiments have shown that increasing the batch size while fixing the remaining parameters at the same level can significantly improve the recognition accuracy.

**Keywords:** convolutional neural network, pattern recognition, medical images, cerebral aneurysm, computer-aided diagnostics system.

**For citation:** Kruzhalov A.S. Patch-based training of a convolutional neural network in the problem of cerebral aneurysms recognition. *Modeling, Optimization and Information Technology*. 2023;11(2). URL: <https://moitvivr.ru/ru/journal/pdf?id=1341> DOI: 10.26102/2310-6018/2023.41.2.017 (In Russ.).

## Введение

В последние годы исследователям удалось добиться значительных успехов в решении задачи распознавания образов. Это стало возможным благодаря использованию искусственных нейронных сетей (ИНС), в первую очередь, свёрточных. Одной из сфер применения свёрточных нейронных сетей является распознавание патологических изменений на медицинских изображениях [1] в рамках систем компьютерной автоматизированной диагностики.

Важной задачей в этой сфере является задача распознавания аневризм сосудов головного мозга. Аневризма представляет собой растяжение или истончение стенки артерии или вены, из-за чего стенка выпячивается. В настоящее время «золотым стандартом» диагностики цереброваскулярной патологии является дигитальная субтракционная церебральная ангиография [2], которая позволяет получить трехмерную визуализацию церебральных сосудов (ангиограмму). Путем анализа ангиограммы врач может определить наличие аневризмы, ее строение и отношение к другим сосудам. Применение систем компьютерной автоматизированной диагностики для распознавания церебральных аневризм по результатам ангиографии позволяет существенно повысить эффективность работы специалистов [3, 4].

На сегодняшний день уже накоплен определенный опыт применения ИНС для решения задачи распознавания церебральных аневризм. В большинстве работ для оценки точности решения задачи сегментации аневризм используется коэффициент Дайса-Сёренсена (*DSC*). В работе Park et al. [3] предлагается модель свёрточной нейронной сети HeadXNet. Авторы провели исследование влияния использования радиологами нейронной сети при анализе и интерпретации ангиограмм на точность выявления аневризм. Статистический анализ полученных результатов доказал значимое повышение показателей чувствительности (англ. *sensitivity*) и точности (англ. *accuracy*) при использовании нейронной сети в качестве вспомогательного инструмента. В работе Shi et al. [4] была предложена модель свёрточной нейронной сети DAResUNet. Особенностью данной модели стало добавление механизма внимания (англ. *attention*), который позволил строить более устойчивые признаковые представления. Наилучшая из обученных в данной работе моделей достигла медианной точности  $DSC = 0,75$ . В работе Zhu et al. [5] проводится исследование эффективности обучения трехмерных свёрточных нейронных сетей различных архитектур (рассматриваются модели 3D UNet [6], VNet [7] и 3D Res-UNet [8]) в зависимости от различных процедур предварительной обработки данных и размера используемых для обучения фрагментов изображений. Авторы отмечают, что наилучшие результаты были получены при помощи архитектуры 3D UNet ( $DSC = 0,818$ ). Также авторы отмечают существенное влияние

размера используемых при обучении фрагментов изображений на получаемый результат.

Во всех упомянутых выше работах используется методика обучения свёрточной нейронной сети на основе фрагментов исходных изображений. Это связано с тем, что ангиограммы представляют собой трехмерные тензоры достаточно больших размеров, и поэтому использовать их целиком при обучении нейронной сети, как правило, не представляется возможным ввиду ограниченности памяти графического процессора (GPU). Эта проблема решается путем разбиения исходного изображения на отдельные фрагменты. Такая методика обучения свёрточной нейронной сети «по частям» (англ. patch-based training) [9] возможна только для «полностью свёрточных» сетей (англ. fully convolutional network) [10], в которых используются только свёрточные слои и которые, как следствие, не накладывают жестких ограничений на размер входных данных (фрагментов изображений). При этом возникает проблема выбора оптимального размера фрагментов изображений для обучения нейронной сети, исходя из особенностей решаемой задачи и используемой архитектуры нейронной сети.

Преимущество свёрточных нейронных сетей перед другими алгоритмами распознавания состоит в том, что они способны извлекать из данных пространственные закономерности – свойства, характерные для групп смежных пикселей. Выделение этих свойств осуществляется при помощи подбора значений ядер фильтров (сверток) в процессе обучения нейронной сети. При этом из изображения извлекаются локальные характеристики, учитывающие определенный ограниченный контекст обрабатываемой области (чем больше размер ядра фильтра, тем больший контекст учитывается). Это делает свёрточные нейронные сети эквивариантными (англ. equivariance) относительно определенных преобразований входных данных (например, перемещения объекта интереса), что имеет положительный эффект на их работу. Однако, при использовании методики обучения «по частям» появляется необходимость определять «контекст» не только в смысле размеров ядер фильтров в свёрточных слоях, но и в смысле размера извлекаемых фрагментов, на основе которых проводится обучение. В большинстве работ авторы не акцентируют на этом внимание, однако размер фрагментов, способ их извлечения из изображения и принципы формирования наборов обучающих примеров на основе извлеченных фрагментов оказывают существенное влияние на процесс обучения нейронной сети.

В данной работе рассматривается методика обучения свёрточной нейронной сети на основе фрагментов медицинских изображений применительно к решению задачи распознавания церебральных аневризм на основе ангиограмм сосудов головного мозга. Цель исследования – провести анализ влияния размера используемого контекста (фрагмента изображения) на эффективность процесса обучения свёрточной нейронной сети.

### **Материалы и методы**

Для построения алгоритма распознавания были использованы данные, опубликованные в рамках соревнования Cerebral Aneurysm Detection (CADA) [11]. 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 0,5 мм.

Одной из особенностей рассматриваемых данных является их трехмерная структура. Учет этой структуры необходим для построения эффективного алгоритма для распознавания аневризм. Это иллюстрирует пример, приведенный на Рисунке 1.

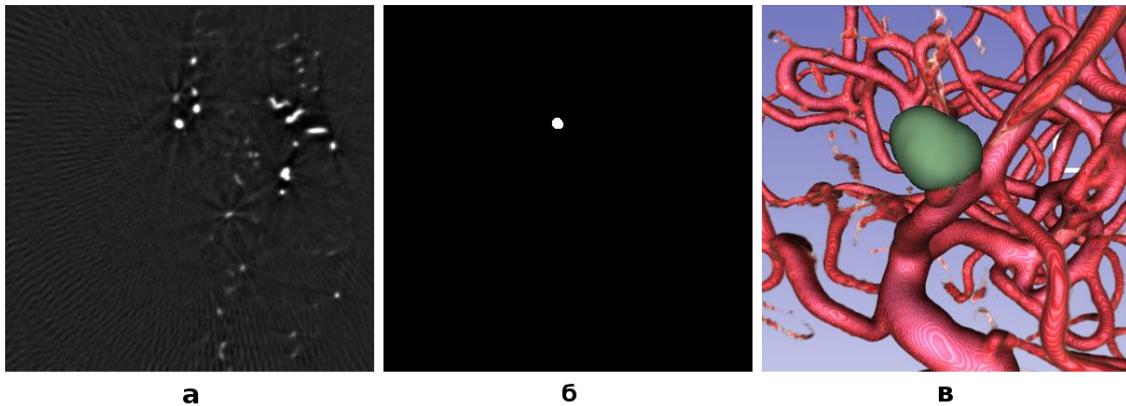


Рисунок 1 – Срез исходного изображения (а), маска (б) и 3D-визуализация (в) (A025)  
Figure 1 – Slice of the image (a), segmentation mask (b) and 3D visualization (c) (A025)

На приведенном изображении представлен двумерный срез снимка из анализируемых данных, а также маска сегментации, которая ему соответствует. По этому примеру видно, что, не располагая дополнительной информацией о пространственной структуре данных, отличить аневризму от здорового сосуда не представляется возможным. Также на изображении представлена 3D-визуализация рассматриваемого снимка с выделенной на ней аневризмой.

В качестве алгоритма распознавания в данной работе используется трехмерная свёрточная нейронная сеть (Рисунок 2). Предлагаемая архитектура нейронной сети основана на архитектуре UNet [12]. Эта архитектура подразумевает выделение в структуре нейронной сети двух больших блоков: кодировщика и декодировщика. Кодировщик «сжимает» исходное изображение, чтобы получить признаки, информативные для распознавания аневризм, а декодировщик – преобразует это признаковое описание в бинарную маску, которая задает положение аневризмы на изображении. Эти два блока имеют симметричную структуру.

Между соответствующими уровнями кодировщика и декодировщика есть «сквозные» связи, по которым выходные карты признаков кодировщика подаются на вход декодировщика в дополнение к картам признаков, полученных на более глубоких слоях нейронной сети. Такие «сквозные» связи позволяют в большей степени сохранять пространственное разрешение, которое частично теряется из-за применения операции субдискретизации при переходе к более обобщенным (глубоким) уровням представления.

При проходе через «сквозные» связи данные пропускаются через модуль внимания (англ. attention gate) [13], который позволяет придать бóльшие веса («сфокусировать внимание») тем областям карт признаков, которые содержат характерные черты, присущие объекту интереса на исходном изображении [14].

На представленной схеме подсчитаны размеры карт признаков, полученные для входного изображения размера  $180 \times 180 \times 180$ . При этом на выходе получается маска сегментации размером  $92 \times 92 \times 92$ . При вычислении размера карт признаков, получаемых на выходе из свёрточного слоя, была использована следующая формула

$$W_{out} = \frac{W_{in} - F + 2P}{S} + 1,$$

где  $W_{out}$  – размер выходной карты признаков,  $W_{in}$  – размер входной карты признаков,  $F$  – размер фильтра,  $P$  – величина отступа (англ. padding),  $S$  – шаг фильтра (англ. stride).

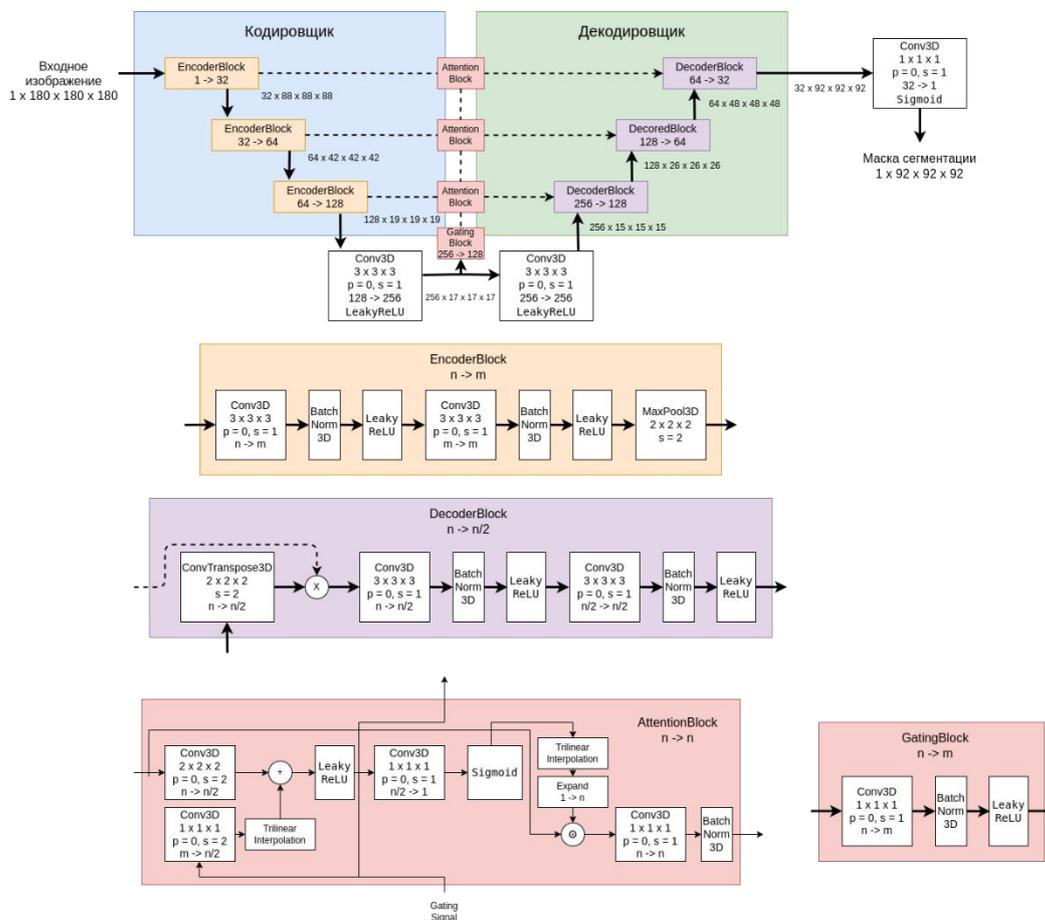


Рисунок 2 – Архитектура нейронной сети  
Figure 2 – Neural network architecture

Постепенное уменьшение размеров карт признаков и, как следствие, выходной маски сегментации происходит из-за того, что в свёрточных слоях не используются дополнительные отступы ( $P = 0$ ). Это связано с тем, что мы работаем лишь с фрагментом изображения (размером  $180 \times 180 \times 180$ ) и должны учитывать окружающий его контекст. Таким образом, получается, что для формирования маски сегментации размера  $92 \times 92 \times 92$  учитываются те области изображения, которые ее окружают. В дальнейшем это позволит построить «бесшовный» прогноз для всего изображения на основе прогнозов для отдельных фрагментов.

Перед подачей на вход нейронной сети изображения подвергались процедуре предварительной обработки. Она включает в себя следующие шаги: ресемплинг, стандартизацию, сигмовидное преобразование (англ. sigmoid transformation), аугментации. Ресемплинг проводится с целью привести все изображения к единому масштабу (размер вокселя – 0,54 мм). Стандартизация необходима для унификации распределения значений вокселей в рамках каждого изображения. Аугментации были применены для предотвращения переобучения: с вероятностью 0,3 к изображению применялось отражение, и с той же вероятностью – аффинные преобразования.

Сигмовидное преобразование было использовано как аналог порогового преобразования для выделения сосудов. Значение каждого вокселя было преобразовано по формуле:

$$x'_{k,l,m} = \frac{1}{1 + e^{-(x_{k,l,m}-t)'}}$$

где  $x_{k,l,m}$  – исходное значение вокселя в позиции  $k, l, m$ ;  $x'_{k,l,m}$  – преобразованное значение вокселя в позиции  $k, l, m$ ;  $t$  – значение порога, вычисленное по методу треугольника [15].

Для обучения нейронной сети был выбран алгоритм Adam. В качестве целевой функции  $L$  использовалась сумма взвешенной бинарной перекрестной энтропии и DiceLoss:

$$L(\mathbf{w}) = \sum_{i=1}^n [L_{BCE}^{(i)}(\mathbf{w}) + L_{DC}^{(i)}(\mathbf{w})],$$

где  $\mathbf{w}$  – вектор настраиваемых параметров,  $n$  – количество объектов в обучающей выборке,  $L_{BCE}(\mathbf{w})$  – бинарная перекрестная энтропия,  $L_{DC}(\mathbf{w})$  – Dice Loss. Ввод весовых коэффициентов в перекрестную энтропию необходим ввиду наличия дисбаланса классов – объект интереса занимает лишь малую часть изображения.

Ввиду ограниченности объема памяти GPU, с помощью обученной нейронной сети можно получить прогноз только для отдельного фрагмента исходного изображения. Чтобы получить прогноз для всего изображения, необходимо разбить его на пересекающиеся фрагменты, получить прогноз для каждого фрагмента, а затем «склеить» получившиеся результаты. Для этого сначала исходное изображение размера  $256 \times 256 \times 220$  дополняется нулями по краям, чтобы получить размер  $264 \times 264 \times 220$  (в общем случае размер изображения должен быть кратен размеру выхода нейронной сети для одного фрагмента). Затем изображение разбивается на 180 пересекающихся фрагментов размера  $132 \times 132 \times 132$ , которые берутся с шагом 44. После выделения фрагментов каждый из них пропускается через нейронную сеть, и полученные предсказания (каждое из них размера  $44 \times 44 \times 44$ ) объединяются в итоговое.

### Результаты и обсуждение

При написании программного кода для проведения вычислительных экспериментов был использован язык программирования Python с применением следующих программных библиотек: PyTorch, TorchIO, NumPy, scikit-image, SimpleITK.

Для обучения нейронных сетей был использован алгоритм Adam. Применены следующие значения параметров алгоритма:  $\alpha = 10^{-3}$ ,  $\beta_1 = 0,9$ ,  $\beta_2 = 0,999$ . Обучение продолжалось в течение 100 эпох. Данные были разделены на обучающую и валидационную выборки. В обучающую выборку вошло 88 изображений, а в валидационную – 20. Если значение функции потерь на валидационной выборке не уменьшалось на протяжении 10 эпох подряд, параметр скорости обучения ( $\alpha$ ) уменьшался в 10 раз. Размер пакета (англ. batch size, BS) изображений, по которым вычислялась оценка градиента целевой функции в алгоритме оптимизации, определялся исходя из объема доступной памяти GPU.

Нейронные сети обучались на фрагментах исходных изображений различного размера (Таблица 1). Фрагменты извлекались из изображения случайным образом, но с условием, что по центру фрагмента должна располагаться область интереса (аневризма) или область, соответствующая здоровому сосуду. Для выделения сосудов был использован метод треугольника. Выделение сосудов в данном случае необходимо, чтобы при обучении предъявлять нейронной сети не только положительные примеры, но

и отрицательные (не содержащие области интереса). При этом отрицательные примеры не должны быть слишком простыми (относиться к «пустым» областям изображения, не содержащим сосуды). При случайном сэмплировании фрагментов вероятности выбора были заданы таким образом, что фрагменты с областью интереса выбирались в 4 раза чаще. Из каждого изображения обучающей выборки было извлечено по 8 фрагментов. Таким образом, за одну эпоху нейронной сети предъявлялось 704 различных обучающих примера (фрагмента изображения). Для изображений из валидационной выборки извлекались пересекающиеся фрагменты с целью получения бесшовного прогноза для исходного полноразмерного изображения.

В рамках проведения вычислительных экспериментов было обучено 6 нейронных сетей описанной выше архитектуры. Для разных нейронных сетей варьировались размеры фрагментов исходных изображений, которые использовались для обучения, а также размер пакета (англ. batch size). Размер пакета менялся исходя из доступного объема памяти, чтобы компенсировать уменьшение объема обрабатываемых данных, связанного с уменьшением размера фрагмента. Для оценки качества работы обученных нейронных сетей было вычислено медианное значение коэффициента Дайса-Сёрнсена (*DSC*) для изображений из валидационной выборки. Маски сегментации были получены при помощи описанной ранее схемы разбиения изображения на пересекающиеся фрагменты. Полученные значения приведены в Таблице 1. Для сравнения были выбраны лучшие модели, полученные в процессе обучения.

Таблица 1 – Результаты вычислительных экспериментов  
Table 1 – Results of computational experiments

№	Размер фрагмента → Выходной размер маски	BS	DSC
1	100 → 12	1	0,23
2	100 → 12	5	0,85
3	132 → 44	1	0,47
4	132 → 44	2	0,66
5	180 → 92	1	0,43
6	196 → 108	1	0,30

Как видно по приведенным результатам, наивысшей точности распознавания ( $DSC = 0,85$ ) удалось достичь модели, при обучении которой использовались фрагменты размера 100 в комбинации с размером пакета, равным 5. При этом видно, что оставшиеся модели показали существенно более низкие результаты.

Для статистического анализа полученных результатов был использован критерий Фридмана, так как в данном случае необходимо сравнить несколько зависимых выборок. Каждая выборка соответствует определенной нейронной сети и состоит из значений коэффициента Дайса-Сёрнсена, вычисленных при помощи этой нейронной сети для изображений из валидационной выборки (валидационная выборка фиксирована для всех нейронных сетей). Исходя из полученного значения статистики критерия ( $S = 40,41$ ;  $p - value = 1,23 \cdot 10^{-7}$ ) и уровня значимости  $\alpha = 0,05$ , можно прийти к выводу, что наблюдаемые различия статистически значимы.

Для проведения попарных сравнений был использован критерий Уилкоксона ( $W$ ) с контролем ожидаемой доли ложных отклонений гипотез (англ. false discovery rate, FDR) на уровне  $\alpha = 0,05$  по методу Бенджамини-Хохберга (FDR B&H). Результаты попарных сравнений приведены в Таблице 2. Каждая из рассматриваемых выборок обозначена в таблице через размер фрагмента, который был использован при обучении нейронной сети, и размер пакета (указан в скобках). Если размер пакета не указан, значит он равен единице.

Таблица 2 – Результаты попарных сравнений  
Table 2 – Results of pairwise comparisons

№	Сравниваемая пара	<i>W</i>	P-value	FDR B&H
1	<b>100 (1) – 100 (5)</b>	1	3,8e-6	<b>5,7e-5</b>
2	<b>100 (1) – 132 (1)</b>	45	0,02	<b>0,036</b>
3	<b>100 (1) – 132 (2)</b>	6	2,7e-5	<b>0,0002</b>
4	100 (1) – 180	61	0,17	0,23
5	100 (1) – 196	79	0,35	0,44
6	<b>100 (5) – 132 (1)</b>	25,5	0,002	<b>0,005</b>
7	<b>100 (5) – 132 (2)</b>	36,5	0,009	<b>0,016</b>
8	<b>100 (5) – 180</b>	13	0,00017	<b>0,0006</b>
9	<b>100 (5) – 196</b>	13	0,00017	<b>0,0006</b>
10	<b>132 (1) – 132 (2)</b>	18	0,0005	<b>0,0014</b>
11	132 (1) – 180	91	0,62	0,66
12	132 (1) – 196	78,5	0,76	0,76
13	<b>132 (2) – 180</b>	30,5	0,004	<b>0,008</b>
14	<b>132 (2) – 196</b>	26,5	0,002	<b>0,005</b>
15	180 – 196	81	0,57	0,66

Как видно по приведенным результатам, статистически значимо от всех остальных выборок отличаются выборки 100 (5) и 132 (2). При этом между ними также наблюдаются значимые различия. Отличительной особенностью этих выборок является значение размера пакета (BS) больше единицы. Также для них были получены наивысшие значения точности распознавания (DSC) среди всех проведенных экспериментов. Можно отметить, что для пары 100 (1) – 132 (1) было получено наивысшее р-значение среди всех результатов, признанных статистически значимыми. Наблюдаемые при этом различия можно объяснить тем, что точность распознавания для выборки 100 (1), которая соответствует наименьшему размеру фрагмента из рассматриваемых, оказалась наименьшей среди всех проведенных экспериментов. Между остальными парами выборок не наблюдается статистически значимых различий.

Для оценки распределения значений сравниваемых показателей в рамках каждой из рассматриваемых выборок были построены диаграммы размаха, представленные на Рисунке 3.

По приведенным графикам видно, что наивысшее значение медианы распределения (0,85) и наименьший разброс относительно нее были получены для выборки 100 (5). Выборки 132 (1), 180 и 196 имеют схожие распределения, охватывающие почти весь диапазон возможных значений DSC, что указывает на нестабильность работы моделей, соответствующих данным выборкам. Для выборки 100 (1), напротив, наблюдается относительно небольшой разброс значений, однако, большая часть из них не превосходит порога  $DSC = 0,5$ , что свидетельствует о низкой точности распознавания соответствующей модели. Выборка 132 (2) имеет существенно более высокое значение медианы (0,66), чем большинство остальных выборок, и при этом обладает более высоким разбросом значений, чем 100 (5). Модель, соответствующая выборке 132 (2), занимает промежуточное значение по точности и стабильности работы между выборкой 100 (5) и всеми остальными. Полученные результаты демонстрируют существенное влияние показателя BS на точность и стабильность работы обученных моделей: при увеличении размера пакета растет медианная точность распознавания (DSC) и уменьшается разброс значений точности прогнозов модели.

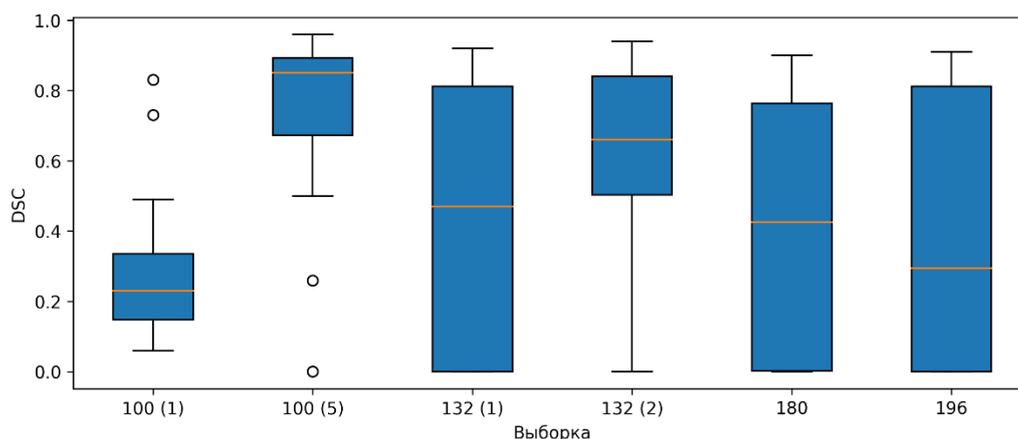


Рисунок 3 – Диаграммы размаха значений DSC для рассматриваемых выборок  
 Figure 3 – DSC box plots for the samples under consideration

Для качественной оценки полученных результатов были построены визуализации предсказаний наилучшей модели для полноразмерных изображений. Пример такой визуализации представлен на Рисунке 4.

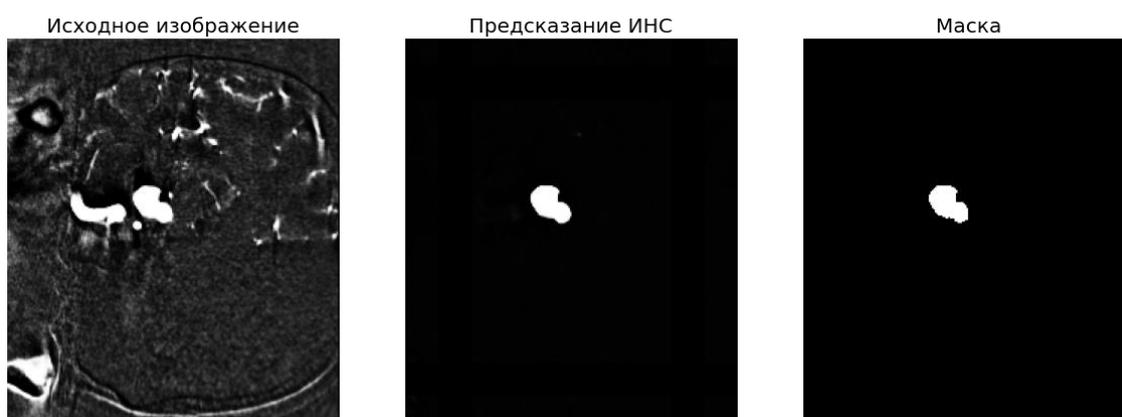


Рисунок 4 – Пример отображения результатов распознавания (A121)  
 Figure 4 – Example of displaying recognition results (A121)

По приведенному изображению видно, что нейронная сеть справилась с задачей достаточно хорошо ( $DSC = 0,92$ ), сумев выделить аневризму на фоне близлежащих сосудов. Для большинства аневризм среднего и большого размера удалось получить достаточно высокую точность распознавания. Проблемы отмечаются для аневризм небольшого размера, это также отмечают и авторы других исследований [4, 16]. В целом, можно сказать, что полученные результаты точности распознавания сопоставимы с результатами недавних исследований других авторов [4, 5, 14, 16].

### Заключение

В данной работе был проведен анализ эффективности методики обучения свёрточной нейронной сети по фрагментам исходных изображений, с точки зрения влияния размера используемых фрагментов на точность распознавания. Была предложена архитектура полностью свёрточной нейронной сети для решения задачи распознавания церебральных аневризм, а также методика предварительной обработки данных и построения «бесшовного» прогноза, основанная на разбиении исходного

изображения на пересекающиеся фрагменты. В результате статистического анализа результатов вычислительных экспериментов было выявлено, что использование фрагментов небольшого размера в комбинации с увеличением размера пакета обучающих примеров позволяет получить значимо более высокую точность распознавания при решении рассматриваемой задачи, чем использование большого размера фрагмента с единичным размером пакета. Это можно объяснить тем, что небольшой размер фрагментов позволяет увеличить размер пакета изображений, по которым вычисляется градиент, а включение в пакет фрагментов разных изображений, в свою очередь, позволяет получить более точную оценку градиента, что способствует увеличению скорости обучения и точности получаемых результатов.

### СПИСОК ИСТОЧНИКОВ

1. Дороничева А.В., Савин С.З. Методы распознавания медицинских изображений для задач компьютерной автоматизированной диагностики. *Современные проблемы науки и образования*. 2014;(4).
2. Берестов В.В. *Эмболизация церебральных аневризм в остром периоде геморрагического инсульта: дис. ... канд. мед. наук: 3.1.10*. Новосибирск; 2021. 138 с.
3. Park A., Chute C., Rajpurkar P., Lou J., Ball R.L., Shpanskaya K., et al. Deep Learning-Assisted Diagnosis of Cerebral Aneurysms Using the HeadXNet Model. *JAMA network open*. 2019;2(6):e195600. Available from: <https://jamanetwork.com/journals/jamanetworkopen/fullarticle/2735471>.
4. Shi Z., Miao C., Schoepf U.J., Savage R.H., Dargis D.M., Pan C, et al. A clinically applicable deep-learning model for detecting intracranial aneurysm in computed tomography angiography images. *Nature Communications*. 2020;11(1):1–11. DOI: 10.1038/s41467-020-19527-w.
5. Zhu G., Luo X., Yang T., Cai L., Yeo J.H., Yan G., et al. Deep learning-based recognition and segmentation of intracranial aneurysms under small sample size. *Frontiers in Physiology*. 2022;13:2580.
6. Cicek O., Abdulkadir A., Lienkamp S.S., Brox T., Ronneberger O. 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI*. 2016. Available from: <http://arxiv.org/abs/1606.06650>.
7. Milletari F., Navab N., Ahmadi S.A. V-net: Fully convolutional neural networks for volumetric medical image segmentation. *2016 fourth international conference on 3D vision (3DV)*. 2016:565–571.
8. Kerfoot E., Clough J., Oksuz I., Lee J., King A.P., Schnabel J.A. Left-ventricle quantification using residual U-Net. *Statistical Atlases and Computational Models of the Heart. Atrial Segmentation and LV Quantification Challenges: 9th International Workshop, STACOM 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers 9*. 2019:371–380.
9. Brutzkus A., Globerson A., Malach E., Netser A.R., Shalev-Schwartz S. Efficient Learning of CNNs using Patch Based Features. *International Conference on Machine Learning*. 2022:2336–2356.
10. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015:3431–3440.
11. CADA-Cerebral Aneurysm Detection. Grand Challenge; Available from: <https://cada.grand-challenge.org/> (accessed on 20.09.2022).

12. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 2015;9351:234–241.
13. Oktay O., Schlemper J., Folgoc L.L., Lee M., Heinrich M., Misawa K., et al. *Attention U-Net: Learning Where to Look for the Pancreas*; 2018. Available from: <https://arxiv.org/abs/1804.03999v3>.
14. Su Z., Jia Y., Liao W., Lv Y., Dou J., Sun Z., et al. 3D attention U-Net with pretraining: a solution to CADA-Aneurysm segmentation challenge. *Cerebral Aneurysm Detection and Analysis: First Challenge, CADA 2020, Held in Conjunction with MICCAI 2020, Lima, Peru, October 8, 2020, Proceedings 1*. 2021:58–67.
15. Kruzhalov A., Philippovich A. Analysis of Thresholding Methods for the Segmentation of Brain Vessels. In: *Recent Trends in Analysis of Images, Social Networks and Texts: 10th International Conference, AIST 2021, Tbilisi, Georgia, December 16–18, 2021, Revised Selected Papers*. 2022:85–95.
16. Shahzad R., Pennig L., Goertz L., Thiele F., Kabbasch C., Schlamann M., et al. Fully automated detection and segmentation of intracranial aneurysms in subarachnoid hemorrhage on CTA using deep learning. *Scientific Reports*. 2020;10(1):1–12.

## REFERENCES

1. Doronicheva A. V., Savin S. Z. Methods of medical image recognition for computer-aided diagnostics. *Sovremennye problemy nauki i obrazovaniya = Modern problems of science and education*. 2014;(4). (In Russ.).
2. Berestov V.V. *Embolization of cerebral aneurysms in case of an acute hemorrhagic stroke*. Candidate's dissertation. Novosibirsk; 2021. 138 p.
3. Park A., Chute C., Rajpurkar P., Lou J., Ball R.L., Shpanskaya K., et al. Deep Learning-Assisted Diagnosis of Cerebral Aneurysms Using the HeadXNet Model. *JAMA network open*. 2019;2(6):e195600. Available from: <https://jamanetwork.com/journals/jamanetworkopen/fullarticle/2735471>.
4. Shi Z., Miao C., Schoepf U.J., Savage R.H., Dargis D.M., Pan C, et al. A clinically applicable deep-learning model for detecting intracranial aneurysm in computed tomography angiography images. *Nature Communications*. 2020;11(1):1–11. DOI: 10.1038/s41467-020-19527-w.
5. Zhu G., Luo X., Yang T., Cai L., Yeo J.H., Yan G., et al. Deep learning-based recognition and segmentation of intracranial aneurysms under small sample size. *Frontiers in Physiology*. 2022;13:2580.
6. Cicek O., Abdulkadir A., Lienkamp S.S., Brox T., Ronneberger O. 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI*. 2016. Available from: <http://arxiv.org/abs/1606.06650>.
7. Milletari F., Navab N., Ahmadi S.A. V-net: Fully convolutional neural networks for volumetric medical image segmentation. *2016 fourth international conference on 3D vision (3DV)*. 2016:565–571.
8. Kerfoot E., Clough J., Oksuz I., Lee J., King A.P., Schnabel J.A. Left-ventricle quantification using residual U-Net. *Statistical Atlases and Computational Models of the Heart. Atrial Segmentation and LV Quantification Challenges: 9th International Workshop, STACOM 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers 9*. 2019:371–380.

9. Brutzkus A., Globerson A., Malach E., Netzer A.R., Shalev-Schwartz S. Efficient Learning of CNNs using Patch Based Features. *International Conference on Machine Learning*. 2022:2336–2356.
10. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015:3431–3440.
11. CADA-Cerebral Aneurysm Detection. Grand Challenge; Available from: <https://cada.grand-challenge.org/> (accessed on 20.09.2022).
12. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. 2015;9351:234–241.
13. Oktay O., Schlemper J., Folgoc L.L., Lee M., Heinrich M., Misawa K., et al. *Attention U-Net: Learning Where to Look for the Pancreas*; 2018. Available from: <https://arxiv.org/abs/1804.03999v3>.
14. Su Z., Jia Y., Liao W., Lv Y., Dou J., Sun Z., et al. 3D attention U-Net with pretraining: a solution to CADA-Aneurysm segmentation challenge. *Cerebral Aneurysm Detection and Analysis: First Challenge, CADA 2020, Held in Conjunction with MICCAI 2020, Lima, Peru, October 8, 2020, Proceedings 1*. 2021:58–67.
15. Kruzhalov A., Philippovich A. Analysis of Thresholding Methods for the Segmentation of Brain Vessels. In: *Recent Trends in Analysis of Images, Social Networks and Texts: 10th International Conference, AIST 2021, Tbilisi, Georgia, December 16–18, 2021, Revised Selected Papers*. 2022:85–95.
16. Shahzad R., Pennig L., Goertz L., Thiele F., Kabbasch C., Schlamann M., et al. Fully automated detection and segmentation of intracranial aneurysms in subarachnoid hemorrhage on CTA using deep learning. *Scientific Reports*. 2020;10(1):1–12.

#### ИНФОРМАЦИЯ ОБ АВТОРЕ / INFORMATION ABOUT THE AUTHOR

**Кружалов Алексей Сергеевич**, аспирант, преподаватель кафедры инфокогнитивных технологий, Московский политехнический университет, Москва, Российская Федерация. *e-mail*: [alexkruzhalov@gmail.com](mailto:alexkruzhalov@gmail.com)  
ORCID: [0000-0003-0004-2334](https://orcid.org/0000-0003-0004-2334)

**Aleksey Sergeevich Kruzhalov**, Postgraduate Student, Lecturer at the Chair of Infocognitive Technologies, Moscow Polytechnic University, Moscow, the Russian Federation.

*Статья поступила в редакцию 05.04.2023; одобрена после рецензирования 04.05.2023; принята к публикации 06.06.2023.*

*The article was submitted 05.04.2023; approved after reviewing 04.05.2023; accepted for publication 06.06.2023.*