

Модель сверточной нейронной сети для сегментации магнитно-резонансных изображений с опухолями головного мозга

И.О. Никишев¹, Г.С. Сергеев², В.Ю. Верещагин¹, А.Л. Кривошапкин^{2, 3, 4}

¹ *Московский политехнический университет
107023, г. Москва, ул. Большая Семёновская, 38*

² *Европейский Медицинский Центр
129090, г. Москва, ул. Щепкина, 35*

³ *Российский университет дружбы народов им. Патриса Лумумбы
117198, г. Москва, ул. Миклухо-Маклая, 6*

⁴ *Национальный медицинский исследовательский центр им. академика Е.Н. Мешалкина
630055, г. Новосибирск, ул. Речкуновская, 15*

Резюме

Точная и быстрая сегментация магнитно-резонансных (МР) изображений с объемными образованиями головного мозга, например глиобластом и менингиом, помогает спланировать хирургическое и лучевое лечение, увеличить безопасность и радикальность хирургического вмешательства, что в свою очередь позволяет повысить общую продолжительность жизни пациентов и безрецидивный период. Цель исследования – разработка и оценка эффективности глубокой сверточной нейронной сети с пропускающими соединениями для автоматической сегментации объемных образований головного мозга (менингиомы и глиобластомы) на послеоперационных МР-изображениях, а также анализ ее точности в сравнении с ручной экспертной сегментацией и существующими методами. **Материал и методы.** В работе рассмотрены создание архитектуры, вдохновленной моделью SegResNet, обучение на BraTS2024-GLI и BraTS2024-MEN-RT, описан метод составления обучающей выборки, снижающий дисбаланс классов, и произведен анализ результатов в сравнении с участниками соревнований BraTS 2024. **Результаты и их обсуждение.** Разработанная модель обучена и протестирована на двух наборах данных послеоперационных изображений глиобластомы и менингиомы. Проанализирован ряд метрик для сравнения модели с описанными в литературе методами, а также ее оценки в контексте вариабельности ручной сегментации разными экспертами. Модель достигает коэффициента Сёрнсена 0,8299 при сегментации менингиомы и 0,7028 при сегментации контраст-накапливающей области глиобластомы. Кроме того, сегментация модели дает точную оценку объема области опухоли, о чем свидетельствуют высокие значения коэффициента внутриклассовой корреляции – 0,9661 для менингиомы и 0,8339 для глиобластомы. В целом разработанная модель требует меньше ресурсов для обучения и получения результата. **Заключение.** Модель производит сегментацию как минимум на уровне эксперта, но со значительно меньшей вариабельностью, в особенности при оценке объема опухоли после хирургического лечения.

Ключевые слова: МРТ, нейроонкология, искусственный интеллект, сегментация опухолей головного мозга, глиобластома, менингиома.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Автор для переписки. Сергеев Г.С., e-mail: dr.gs sergeev@gmail.com

Для цитирования. Никишев И.О., Сергеев Г.С., Верещагин В.Ю., Кривошапкин А.Л. Модель сверточной нейронной сети для сегментации магнитно-резонансных изображений с опухолями головного мозга. *Сиб. науч. мед. ж.* 2025;45(6):247–255. doi: 10.18699/SSMJ20250624

Convolutional neural network model for segmentation of magnetic resonance images with brain tumors

I.O. Nikishev¹, G.S. Sergeev², V.Yu. Vereshchagin¹, A.L. Krivoshapkin^{2, 3, 4}

¹ Moscow Polytechnic University
107023, Moscow, Bolshaya Semyonovskaya st., 38

² European Medical Center
129090, Moscow, Shchepkina st., 35

³ Peoples' Friendship University of Russia named after Patrice Lumumb
117198, Moscow, Miklukho-Maklaya st., 6

⁴ Meshalkin National Medical Research Center of Minzdrav of Russia
630055, Novosibirsk, Rechkunovskaya st., 15

Abstract

Accurate and fast segmentation of magnetic resonance (MR) images with volumetric brain formations, such as glioblastomas and meningiomas, helps plan surgical and radiation treatment, increase the safety and radicality of surgical intervention, which in turn allows to increase the overall life expectancy of patients and the disease-free period. It is required for the development and evaluation of the effectiveness of a deep convolutional neural network with transmission connections for automatic segmentation of volumetric brain formations (meningiomas and glioblastomas) on postoperative MR images, as well as analysis of its accuracy in comparison with manual expert segmentation and existing methods. **Material and methods.** The paper considers the creation of an architecture inspired by the SegResNet model, training on BraTS2024-GLI and BraTS2024-MEN-RT, describes a method for compiling a training sample that reduces class imbalance, and analyzes the results in comparison with participants in the BraTS 2024 competition. **Results and discussion.** The developed model was trained and tested on two datasets of postoperative images of glioblastoma and meningioma. Several metrics are analyzed to compare the model with the methods described in the literature, as well as to evaluate it in the context of the variability of manual segmentation by different experts. The model achieves a Sorensen coefficient 0.8299 for meningioma segmentation and 0.7028 for glioblastoma contrast-accumulating region segmentation. In addition, the segmentation of the model provides an accurate estimate of the volume of the tumor area, as evidenced by the high values of the coefficient of intra-class correlation – 0.9661 for meningioma and 0.8339 for glioblastoma. Overall, the developed model requires fewer resources for learning and getting results. **Conclusions.** Model performs segmentation at least at the expert level, but with significantly less variability, especially when assessing the volume of the tumor after surgical treatment.

Key words: MRI, neuro-oncology, artificial intelligence, brain tumor segmentation, glioblastoma, meningioma.

Conflict of interest. The authors declare no conflict of interest.

Correspondence author. Sergeev G.S., e-mail: dr.gs sergeev@gmail.com

Citation. Nikishev I.O., Sergeev G.S., Vereshchagin V.Yu., Krivoschapkin A.L. Convolutional neural network model for segmentation of magnetic resonance images with brain tumors. *Sibirskij nauchnyj medicinskij zhurnal = Siberian Scientific Medical Journal*. 2025;45(6): 247–255. [In Russian]. doi: 10.18699/SSMJ20250624

Введение

Центральный регистр опухолей головного мозга в США в последнем своем отчете декларировал заболеваемость 24,71 случая на 100 000 человек. Наиболее часто встречающейся злокачественной опухолью мозга была глиобластома (14,2 % всех опухолей и 50,1 % всех злокачественных опухолей), а наиболее распространенной незлокачественной опухолью – менингиома (39,7 % всех опухолей и 55,4 % всех незлокачественных опухолей) [1]. В России диагностируют около 34 000 случаев опухолей головного мозга ежегодно. Диагностика опухолей ЦНС включает в себя сочетание клинической оценки пациента (осмотр врачом) и визуализационных исследований [2].

С целью нейровизуализации чаще всего используется МРТ головного мозга с контрастированием. Данный метод позволяет подробно визуализировать структуры головного мозга, определить размер, месторасположение и тип опухоли. Расширенные методы МРТ, такие как функциональная МРТ, трактография, магнитно-резонансная (МР) эластография могут предоставить дополнительную информацию характеристиках опухоли [3–5]. Сегментация опухолей на МРТ головного мозга является критически важной частью работы нейрохирурга, нейрорадиолога, онколога для предоперационного прогнозирования гистологического типа опухоли, планирования операции на нейронавигационных станциях и лучевой терапии, послеоперационной

оценки степени резекции, оценки объемных показателей опухоли в динамике при комбинированном лечении и прогнозировании выживаемости [6–8].

Основополагающим постулатом современной нейрохирургии является максимально безопасная резекция опухоли, позволяющая увеличить общую продолжительность жизни пациентов и безрецидивный период [9, 10]. Для расчета степени резекции опухоли используется соотношение между хирургическим удалением и предоперационным объемом опухоли. Долгое время объем опухоли на разных этапах лечения измерялся с использованием грубых мер, таких как двумерное произведение наибольшего осевого диаметра контраст-накапливающей части опухоли, согласно критериям оценки ответа (RANO) [11]. Ручная сегментация объема требует много времени от специалиста, имеет высокую меж- и внутриэкспертную изменчивость и очень зависит от опыта специалиста [12, 13]. Коэффициент внутриклассовой корреляции (КВК) и обобщенный индекс соответствия (ОИС) между специалистами при определении контраст-накапливающей части глиобластомы до хирургического лечения были на высоком уровне (КВК 0,99, ОИС 0,79), однако показали плохую согласованность в послеоперационном периоде (КВК 0,92, ОИС 0,32) [13].

За последние 20 лет произошло методологическое развитие в области сегментации медицинских изображений. Классические методы включают в себя пороговые модели [14], сегментацию растущей областью [15], классификационные модели [16], такие как К-ближайших соседей, случайный лес и байесовское моделирование. Эти методы используются в трех широко используемых программных пакетах для автоматизированного анализа изображений мозга – SPM5 [17], FreeSurfer [18] и FSL [19].

Для сегментации послеоперационных МР-изображений чаще всего применяются полуавтоматические методы, объединяющие один или несколько алгоритмов. Описано использование комбинации методов, включая энтропийный анализ, кластеризацию, активные контуры, метод множества уровней, анализ по оттенкам серого и построение гистограмм. Однако приведенные подходы инициализируются операторами, а валидируются на одноцентровых наборах данных, и не получили широкого распространения в связи с их сложностью [6, 20–23].

В 2012 г. сверточная нейронная сеть (СНС) обошла классические методы и заняла первое место в конкурсе ISBI'12 по сегментации мембран [24]. С тех пор подходы на основе СНС доминируют в литературе о сегментации медицинских изо-

бражений; наиболее распространена предложенная в 2015 г. архитектура U-Net [25]. Например, в конкурсе по сегментации дооперационных МР-изображений глиобластомы BraTS-2023 практически все лидирующие архитектуры представляют собой варианты U-Net [26]. На сегодняшний день подавляющая часть исследований по автоматизированной сегментации менингиомы и глиобластомы, включая все предыдущие задачи BraTS, сосредоточена исключительно на предоперационных изображениях, что ограничивает клиническую полезность метода [27]. Сегментация послеоперационных изображений является более сложной клинически значимой задачей.

Материал и методы

Данные

В настоящей работе обучение СНС производится на двух наборах данных: BraTS2024-GLI [28] и BraTS2024-MEN-RT [29], включающих послеоперационные изображения глиобластомы и менингиомы.

Предобработка

Набор данных BraTS2024-MEN-RT содержит снимки, размер и ориентация в пространстве которых зависит от аппарата МРТ. Поэтому выполнена регистрация к шаблону SRI24 [30], удалены черепа алгоритмом HD-BET [31], изображения нормализованы (нулевое среднее, единичная дисперсия) и кадрированы для удаления пустого фона. Набор BraTS2024-GLI уже представлен в пространстве SRI24 с удаленным черепом и изображения аналогично нормализованы и кадрированы.

Алгоритм выборки

Обучение моделей проводилось на двухмерных срезах МР-изображений по всем трем измерениям, что позволило увеличить количество обучающих примеров из ограниченного набора данных (по одному примеру на каждый возможный двумерный срез). Отсутствие пространственной информации вдоль оси среза компенсируется подачей соседних срезов модели. Двухмерные свертки требуют меньше вычислений, позволяя проводить больше итераций обучения за тот же промежуток времени.

Для сегментации менингиомы используется метод, когда каждый срез дополняется тремя соседними сверху и снизу (недостающие срезы дублируются) с формированием семиканального изображения, где сегментируется средний (четвертый) срез. Сегментация глиобластомы выполняется на основе четырех МР-модальностей

(T1, T1c, T2, FLAIR). С каждым срезом дополнительно используют два соседних сверху и снизу, получая пятисрезовые последовательности для каждой модальности – всего 20 срезов объединяются в одно двадцатиканальное изображение.

Из-за небольшого размера опухолей большинство срезов не содержит патологических изменений. Для устранения дисбаланса классов перед началом каждой эпохи в выборку добавляют равное число случайных пустых срезов и срезов с патологией, после чего перемешивают данные. Таким образом, половина тренировочных изображений содержит сегментационные метки. Чтобы улучшить способность модели к обобщению, во время обучения применялись аугментация: произвольная вырезка областей размером 96×96 , зеркальное отражение и поворот на 90° с вероятностью 75 %.

Архитектура

Архитектура модели основана на SegResNet [32], сходной с U-Net [25], но использующей суммирование вместо конкатенации, что сокращает число каналов вдвое и уменьшает количество параметров декодера. Оригинальная сеть SegResNet принимает объемные области $160 \times 192 \times 128$ пикселей и использует трехмерную свертку, что тре-

бует большого объема памяти. Для ее обучения авторы использовали NVIDIA Tesla V100 32 Гб с пакетом размера 1. Разработанная нами модель сегментирует менингиому по семиканальным изображениям размером 96×96 , глиобластома – по двадцатиканальным, применяется двумерная свертка. Для обучения достаточно 2,4 Гб видеопамяти (при размере пакета 32), для вывода – всего 80 МБ. Это позволяет использовать модель без специализированной аппаратной части. Архитектура включает энкодер, декодер и точечную свертку (рисунок).

Энкодер состоит из трех уровней, уменьшая разрешение изображения вдвое и удваивая число каналов на каждом этапе. Выходы уровней энкодера суммируются с соответствующими входами декодера. Изображение после энкодера имеет размер $256 \times 12 \times 12$. Декодер включает три слоя, увеличивающих пространственные размеры карты признаков и вдвое сокращающих количество каналов. Билинейная повышающая дискретизация заменена на транспонированные свертки. Все свертки, кроме последней, имеют фильтр 3×3 , финальная свертка (1×1) формирует требуемое число сегментов. Увеличение пакета до 32 привело к замене групповой нормализации на па-

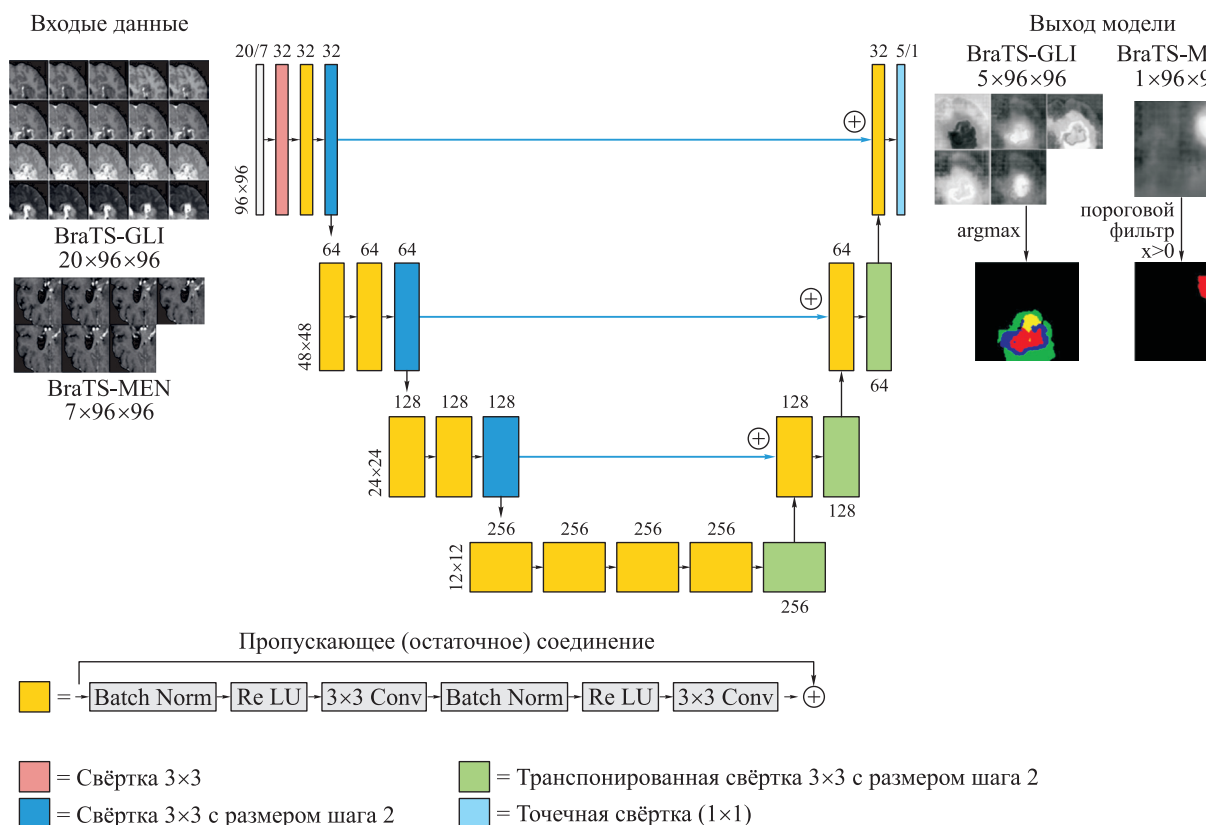


Диаграмма архитектуры разработанной модели
Architecture diagram of the developed model

кетную. Разработанная архитектура используется для обеих задач и различается количеством каналов входного изображения и количеством классов, на которые производится сегментация. Всего модель имеет 6,6 млн параметров.

Обучение

Обе модели обучались с нуля методом адаптивной оценки моментов (Adam) [33] с параметрами $\beta_1 = 0,9$, $\beta_2 = 0,999$ и $\epsilon = 10^{-8}$. Использовался 1-цикловый планировщик скорости обучения [34]. Параметр длины прогрева (warmup learning rate) выбран как 10 % от количества обучающих шагов, т. е. планировщик повышал скорость обучения с 4×10^{-5} до максимальной 1×10^{-3} за изначальные 10 % шагов обучения, а во время оставшихся 90 % шагов скорость обучения постепенно снижалась до 1×10^{-8} . Метод оптимизации и максимальная скорость обучения подбирались методом решетчатого поиска в интервале от 1×10^{-4} до 1×10^{-2} размером шага 0,2 для нескольких методов оптимизации – стохастический градиентный спуск (SGD) и SGD с импульсом Нестерова.

Функция потерь представляет собой сумму фокальной функции потерь [35] и функции потерь на основе «мягкой» дифференцируемой версии коэффициента Сёренсена (soft dice), где пересечение заменяется умножением [36]. Перед вычислением функции потерь к выходу модели применяются сигмоида для бинарной сегментации менингиомы и многопеременная логистическая функция (softmax) для многоклассовой сегментации глиобластомы. Для многоклассовой сегментации функция потерь рассчитывается для каждого класса и усредняется.

Для бинарной сегментации, имея предсказания модели p_i и настоящий класс y_i для i -го пикселя, фокальная функция потерь представляет собой версию взвешенной перекрестной энтропии с дополнительным фактором, фокусирующим обучение на сложных экземплярах:

$$FocalLoss(x_i) = -\alpha_i (1 - x_i)^\gamma \log(x_i),$$

где $x_i = p_i$, если $y_i = 1$, иначе $1 - p_i$; α устанавливается как обратная частота класса на сегментации, т. е. единица, деленная на долю пикселей, на которых присутствует сегментируемый класс, среди всех пикселей; γ – гиперпараметр фокусировки на более сложных экземплярах, в данной работе взято значение 2.

Для бинарной сегментации функция потерь Сёренсена для предсказанной маски сегментации p и реальной маски сегментации y одного обучающего экземпляра вычисляется следующим образом:

$$DiceLoss(p, y) = 1 - \frac{2py + \epsilon}{p + y + \epsilon},$$

где ϵ – небольшой коэффициент, предотвращающий деление на 0, если делитель равен 0. В данной работе $\epsilon = 10^{-5}$.

Обе модели обучались в течение 100 эпох. При обучении на наборе данных BraTS-GLI каждая эпоха включала 419 936 обучающих примеров, составленных согласно алгоритму выборки (раздел 1.3) из 1000 объемных изображений обучающего набора данных. Для валидации использовалась неразмеченная валидационная выборка из соревнования, представленного Synapse. Из оставшихся 350 исследований составлена тестовая выборка для расчета коэффициента Жаккара и KBK. В BraTS-MEN-RT каждая эпоха включала 97 910 обучающих примеров, составленных из 400 исследований, оставшиеся 100 исследований были взяты для валидации. Обучение производилось после завершения соревнования, поэтому дополнительная неразмеченная выборка с Synapse не использовалась. Для сегментации менингиомы обучены две модели: одна на изображениях с удалением черепа, и одна без удаления черепа.

Использование модели

После обучения модель делает предсказание для каждого среза МР-изображений путем перемещения окна. Предсказания усредняются на пересечениях областей. Для увеличения точности сегменты берутся по трем осям с поворотами и отражениями, всего получается 24 варианта исходного трехмерного МР-изображения, прогнозы которых также усредняются. Это важно для интеграции информации третьего измерения при работе двухмерных моделей с объемными изображениями. Например, при сегментации менингиомы коэффициент Сёренсена на тестовой выборке варьирует от 0,576 до 0,625, однако усреднение позволяет добиться повышения коэффициента до 0,804. Также на сегментации удаляются объекты с объемом менее 64 пикселей, что повышает коэффициент Сёренсена до 0,8299.

Результаты

Сегментация менингиомы

Оценка полученной модели производилась по метрикам: коэффициент Сёренсена, мера Жаккара, чувствительность, специфичность, и KBK между объемами опухоли на предсказанных и истинных сегментациях тестового набора. Результаты модели для задачи сегментации менингиомы с удалением и без удаления черепа представлены в табл. 1. Можно сделать вывод, что удаление черепа снижает качество сегментации менингиомы. Вероятной причиной является то, что на многих исследованиях менингиома находится близко к

Таблица 1. Значения метрик для двух вариантов модели при сегментации менингиомы

Table 1. Metric values for two variants of the meningioma segmentation model

Модель	Коэффициент Сёрнсена	Коэффициент Жаккара	Чувствительность	Специфичность	КВК
С удалением черепа	0,7723	0,6781	0,8354	0,9997	0,9661
Без удаления черепа	0,8299	0,7309	0,7518	0,9996	0,9870

Таблица 2. Показатели сегментации послеоперационной глиобластомы для разных классов

Table 2. Segmentation metrics of postoperative glioblastoma for different classes

Класс	Коэффициент Сёрнсена	Коэффициент Жаккара	Чувствительность	Специфичность	КВК
Dice_ET	0,7028	0,6459	0,5328	0,9990	0,8399
Отек	0,8653	0,7667	0,3868	0,9860	0,8426
Некроз	0,6684	0,6151	0,6570	0,9999	0,9267
Область резекции	0,6276	0,6144	0,5763	0,9995	0,8826
Ядро опухоли	0,6956	0,6861	0,5036	0,9991	0,8722
Вся опухоль	0,8777	0,8476	0,4909	0,9865	0,8817

черепа, и в некоторых случаях алгоритм удаления черепа также удаляет часть опухоли. Три команды-участника соревнования BraTS2024-MEN (meningioma segmentation post-treatment) с наибольшими значениями коэффициента Сёрнсена: 0,849, 0,823 и 0,821; полученный в данной статье коэффициент 0,8299 сравним с лидирующими в соревновании командами.

Сегментация глиобластомы

Для задачи сегментации послеоперационных изображений глиобластомы метрики рассчитываются для каждого сегментированного класса, а также для всей опухоли (усиливающая опухоль, отек и некроз) и ее ядра (часть опухоли, накапливающая контраст (Dice_ET), и некроз), описывающего то, что обычно удаляется во время хирургической операции. КВК между объемами каждой области на предсказанных и истинных сегментациях тестового набора рассчитывается по модели ICC(A,1) [37], для сравнения с результатами, полученными в [13], где эта же модель используется для оценки вариативности между экспертами. Результаты представлены в табл. 2. Среди результатов участников соревнования BraTS2024-GLI (glioma segmentation post-treatment) коэффициент Сёрнсена для Dice_ET варьирует от 0,001 до 0,763. Три команды-участника соревнования BraTS2024-GLI (Meningioma segmentation post-treatment) с наибольшим значе-

ниями коэффициента Сёрнсена: 0,763, 0,751 и 0,748. Следовательно, полученное значение 0,703 свидетельствует о хорошем результате и достаточно точной сегментации опухоли.

Обсуждение

СНС (например, U-Net и DeepLab) существенно улучшили сегментацию медицинских изображений, повышая точность диагностики болезней и облегчая обработку сложных данных для выделения органов и опухолей, что важно для планирования терапии и мониторинга пациентов [38]. СНС способны автоматически извлекать признаки из области интереса непосредственно из входных изображений. Результаты по сегментации послеоперационных изображений менингиомы с использованием этого же набора данных несколькими моделями приводятся в работе [39]. Для задачи сегментации менингиомы модель MedNext-Large с трехмерной сверткой $5 \times 5 \times 5$ [40], обученная на комбинации реальных и сгенерированных диффузионными моделями синтетических изображений опухоли, показала наивысшее значение коэффициента Сёрнсена (0,8214). MedNext-Large требует специализированного оборудования, авторы использовали два кластера с 48 и 96 Гб видеопамяти для обучения, но, как видно из табл. 1, менее вычислительно затратная двумерная модель показывает аналогич-

ный коэффициент Сёрнсена.

Оценка результатов может быть также произведена в контексте вариабельности ручной сегментации между разными экспертами. При ранних постоперационных обследованиях КВК объема контраст-накапливающей опухоли на сегментациях экспертов нейрорадиологов с 8–20 годами опыта и 1–5 годами опыта оценивается как 0,92 и 0,60 соответственно; КВК объема не накапливающей контраст опухоли – как 0,25 и 0,15 соответственно, что свидетельствует о крайне низком уровне согласованности [13]. В то же время согласованность объемов опухолей на сегментациях обученной модели с сегментациями экспертов, разметивших набор данных, высокая (более 0,7). ОИС является средним значением коэффициента Жаккара каждой пары сегментаций несколькими экспертами одного пациента. В послеоперационном периоде при сегментации контраст-накапливающей опухоли ОИС оценивается в 0,32 у экспертов с 8–20 годами опыта и в 0,2 у экспертов с 1–5 годами опыта; у обученной модели коэффициент Жаккара равен 0,65. По сравнению с этими показателями, модель имеет низкую вариабельность с тщательной сегментацией несколькими экспертами, предоставленной в наборе данных. Из этого следует, что модель производит сегментацию как минимум на уровне эксперта, но со значительно меньшей вариабельностью, в особенности при оценке объема опухоли.

Заключение

В статье описан и проанализирован подход в сегментации объемных образований головного мозга на разных этапах лечения с помощью глубоких СНС. Использована архитектура с применением пропускающих соединений, осуществляющая сегментацию срезов объемного МР-изображения, но с использованием двумерной свертки. Описан алгоритм составления обучающей выборки двумерных срезов из набора объемных изображений, позволяющий избежать дисбаланса классов при обучении модели. Разработанная модель обучена и протестирована на двух наборах данных послеоперационных изображений глиобластомы и менингиомы. Проанализирован ряд метрик для сравнения модели с описанными в литературе методами, а также ее оценки в контексте вариабельности ручной сегментации разными экспертами. Модель достигает коэффициента Сёрнсена в 0,8299 при сегментации менингиомы и 0,7028 при сегментации контраст-накапливающей области глиобластомы. Кроме того, сегментация модели дает точную

оценку объема области опухоли, о чем свидетельствуют высокие значения КВК – 0,9661 для менингиомы и 0,8339 для глиобластомы.

Список литературы / References

1. Ostrom Q.T., Price M., Neff C., Cioffi G., Waite K.A., Kruchko C., Barnholtz-Sloan J.S. CBTRUS Statistical Report: primary brain and other central nervous system tumors diagnosed in the United States in 2015–2019. *Neuro Oncol.* 2022;24(Supplement_5):v1–v95. doi: 10.1093/neuonc/noac202
2. Клинические рекомендации. Первичные опухоли центральной нервной системы. 2020. Режим доступа: https://oncology-association.ru/wp-content/uploads/2020/09/pervichnye_opuholi_cns.pdf
3. Clinical guidelines. Primary tumors of the central nervous system. 2020. Available at: https://oncology-association.ru/wp-content/uploads/2020/09/pervichnye_opuholi_cns.pdf [In Russian].
4. Idu A.A., Bogaciu N.S., Ciurea A.V. Brain imaging and morphological plasticity in glioblastoma: a literature review. *J. Med. Life.* 2023;16(3):344–347. doi: 10.25122/jml-2022-0201
5. Hughes J.D., Fattahi N., van Gompel J., Arani A., Meyer F., Lanzino G., Link M.J., Ehman R., Huston J. Higher-resolution magnetic resonance elastography in meningiomas to determine intratumoral consistency. *Neurosurgery.* 2015;77(4):653–659. doi: 10.1227/NEU.0000000000000892
6. Yeh F.C., Irimia A., Bastos D.C.D.A., Golby A.J. Tractography methods and findings in brain tumors and traumatic brain injury. *NeuroImage.* 2021;245:118651. doi: 10.1016/j.neuroimage.2021.118651
7. Krivoschapkin A.L., Sergeev G.S., Gaytan A.S., Kalneus L.E., Kurbatov V.P., Abdullaev O.A., Salim N., Bulanov D.V., Simonovich A.E. Automated volumetric analysis of postoperative magnetic resonance imaging predicts survival in patients with glioblastoma. *World Neurosurg.* 2019;126:e1510–e1517. doi: 10.1016/j.wneu.2019.03.142
8. Helland R.H., Ferles A., Pedersen A., Kommers I., Ardon H., Barkhof F., Bello L., Berger M.S., Dunås T., Nibali M.C., ... Bouget D. Segmentation of glioblastomas in early post-operative multi-modal MRI with deep neural networks. *Sci. Rep.* 2023;13(1):18897. doi: 10.1038/s41598-023-45456-x
9. Krivoschapkin A.L., Sergeev G.S., Kalneus L.E., Gaytan A.S., Murtazin V.I., Kurbatov V.P., Volkov A.M., Kostromskaya D.V., Pyatov S.M., Amelin M.E., Duishobaev A.R. New software for preoperative diagnostics of meningeal tumor histologic types. *World Neurosurg.* 2016;90:123–132. doi: 10.1016/j.wneu.2016.02.084
10. Davis M. Glioblastoma: overview of disease and treatment. *Clin. J. Oncol. Nurs.* 2016;20(5):S2–S8. doi: 10.1188/16.CJON.S1.2-8
11. Nanda A., Bir S.C., Maiti T.K., Konar S.K.,

- Missios S., Guthikonda B. Relevance of Simpson grading system and recurrence-free survival after surgery for World Health Organization Grade I meningioma. *J. Neurosurg.* 2017;126(1):201–211. doi: 10.3171/2016.1.JNS151842
11. Wen P.Y., van den Bent M., Youssef G., Cloughesy T.F., Ellingson B.M., Weller M., Galanis E., Barboriak D.P., De Groot J., Gilbert M.R., ... Chang S.M. RANO 2.0: Update to the response assessment in neuro-oncology criteria for high- and low-grade gliomas in adults. *J. Clin. Oncol.* 2023;41(33):5187–5199. doi: 10.1200/JCO.23.01059
12. Berntsen E.M., Stensjøen A.L., Langlo M.S., Simonsen S.Q., Christensen P., Moholdt V.A., Solheim O. Volumetric segmentation of glioblastoma progression compared to bidimensional products and clinical radiological reports. *Acta Neurochir. (Wien).* 2020;162(2):379–387. doi: 10.1007/s00701-019-04110-0
13. Visser M., Müller D.M.J., van Duijn R.J.M., Smits M., Verburg N., Hendriks E.J., Nabuurs R.J.A., Bot J.C.J., Eijgelaar R.S., Witte M., ... de Munck J.C. Inter-rater agreement in glioma segmentations on longitudinal MRI. *Neuroimage Clin.* 2019;22:101727. doi: 10.1016/j.nicl.2019.101727
14. Sahoo P.K., Soltani S., Wong A.K.C. A survey of thresholding techniques. *Computer Vision, Graphics, and Image Processing.* 1988;41(2):233–260. doi: 10.1016/0734-189X(88)90022-9
15. Manousakas I.N., Undrill P.E., Cameron G.G., Redpath T.W. Split-and-merge segmentation of magnetic resonance medical images: performance evaluation and extension to three dimensions. *Comput. Biomed. Res.* 1998;31(6):393–412. doi: 10.1006/cbmr.1998.1489
16. Bezdek J.C., Hall L.O., Clarke L.P. Review of MR image segmentation techniques using pattern recognition. *Med. Phys.* 1993;20(4):1033–1048. doi: 10.1118/1.597000
17. Ashburner J., Friston K.J. Unified segmentation. *Neuroimage.* 2005;26(3):839–851. doi: 10.1016/j.neuroimage.2005.02.018
18. Dale A.M., Fischl B., Sereno M.I. Cortical surface-based analysis. *Neuroimage.* 1999;9(2):179–194. doi: 10.1006/nimg.1998.0395
19. Smith S.M., Jenkinson M., Woolrich M.W., Beckmann C.F., Behrens T.E.J., Johansen-Berg H., Bannister P.R., De Luca M., Drobnjak I., ... Matthews P.M. Advances in functional and structural MR image analysis and implementation as FSL. *Neuroimage.* 2004;23:S208–S219. doi: 10.1016/j.neuroimage.2004.07.051
20. Otsu N. A threshold selection method from gray-level histograms. *IEEE Trans. Syst., Man, Cybern.* 1979;9(1):62–66. doi: 10.1109/TSMC.1979.4310076
21. Cordova J.S., Schreiber E., Hadjipanayis C.G., Guo Y., Shu H.K.G., Shim H., Holder C.A. Quantitative tumor segmentation for evaluation of extent of glioblastoma resection to facilitate multisite clinical trials. *Transl. Oncol.* 2014;7(1):40–W5. doi: 10.1593/tlo.13835
22. Odland A., Server A., Saxhaug C., Breivik B., Groote R., Vardal J., Larsson C., Bjørnerud A. Volumetric glioma quantification: comparison of manual and semi-automatic tumor segmentation for the quantification of tumor growth. *Acta. Radiol.* 2015;56(11):1396–1403. doi: 10.1177/0284185114554822
23. Zeng K., Bakas S., Sotiras A., Akbari H., Rozycki M., Rathore S., Pati S., Davatzikos C. Segmentation of gliomas in pre-operative and post-operative multimodal magnetic resonance imaging volumes based on a hybrid generative-discriminative framework. *Brainlesion.* 2016;10154:184–194. doi: 10.1007/978-3-319-55524-9_18
24. Cireşan D.C., Giusti A., Gambardella L.M., Schmidhuber J. Deep neural networks segment neuronal membranes in electron microscopy images. *Advances in Neural Information Processing Systems: proc. conf., Lake Tahoe Nevada, December 3–6, 2012.* Red Hook: Curran Associates Inc, 2012. 2843–2851.
25. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: *Lecture Notes in Computer Science.* New York: Springer International Publishing, 2015; 234–241. doi: 10.1007/978-3-319-24574-4_28
26. Isensee F., Jäger P.F., Full P.M., Vollmuth P., Maier-Hein K.H. nnU-Net for Brain Tumor Segmentation. In: *Lecture Notes in Computer Science.* New York: Springer International Publishing, 2021; 118–132. doi: 10.1007/978-3-030-72087-2_11
27. LaBella D., Adewole M., Alonso-Basanta M., Altes T., Anwar S.M., Baid U., Bergquist T., Bhalerao R., Chen S., Chung V., ... Calabrese E. The ASNR-MICCAI Brain Tumor Segmentation (BraTS) Challenge 2023: intracranial meningioma. Published online May 12, 2023. doi: 10.48550/arXiv.2305.07642
28. de Verdier M.C., Saluja R., Gagnon L., LaBella D., Baid U., Tahon N.H., Foltyn-Dumitru M., Zhang J., Alafif M., Baig S., ... Rudie J.D. The 2024 brain tumor segmentation (BraTS) challenge: glioma segmentation on post-treatment MRI. Published online 2024. doi: 10.48550/ARXIV.2405.18368
29. LaBella D., Schumacher K., Mix M., Leu K., McBurney-Lin S., Nedelec P., Villanueva-Meyer J., Shapey J., Vercauteren T., Chia K., ... Calabrese E. Brain Tumor Segmentation (BraTS) Challenge 2024: meningioma radiotherapy planning automated segmentation. Published online 2024. doi: 10.48550/ARXIV.2405.18383
30. Rohlfing T., Zahr N.M., Sullivan E.V., Pfefferbaum A. The SRI24 multichannel atlas of normal adult human brain structure. *Hum. Brain. Mapp.* 2010;31(5):798–819. doi: 10.1002/hbm.20906
31. Isensee F., Schell M., Pflueger I., Brugnara G., Bonekamp D., Neuberger U., Wick A., Schlemmer H., Heiland S., Wick W., Bendszus M., Maier-Hein K.H.,

- Kickingereder P. Automated brain extraction of multi-sequence MRI using artificial neural networks. *Hum. Brain. Mapp.* 2019;40(17):4952–4964. doi: 10.1002/hbm.24750
32. Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization. In: *Lecture Notes in Computer Science*. New York: Springer International Publishing, 2019; P. 311–320. doi: 10.1007/978-3-030-11726-9_28
33. Kingma D.P., Ba J. Adam: A method for stochastic optimization. Published online January 30, 2017. doi: 10.48550/arXiv.1412.6980
34. Smith L.N., Topin N. Super-convergence: very fast training of neural networks using large learning rates. *Artificial Intelligence and Machine Learning for Multi-Domain Operations Applications*: proc. conf., Baltimore, April 14–18, 2019. Bellingham: SPIE, 2019; 1100612. doi: 10.1117/12.2520589
35. Lin T.Y., Goyal P., Girshick R., He K., Dollar P. Focal Loss for Dense Object Detection. *IEEE International Conference on Computer Vision*: proc. conf., Venice, October 22–29, 2017. Piscataway: IEEE, 2017; 2999–3007. doi: 10.1109/ICCV.2017.324
36. Sudre C.H., Li W., Vercauteren T., Ourselin S., Jorge Cardoso M. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In: *Lecture Notes in Computer Science*. New York: Springer International Publishing, 2017; 240–248. doi: 10.1007/978-3-319-67558-9_28
37. McGraw K.O., Wong S.P. Forming inferences about some intraclass correlation coefficients. *Psychol. Methods.* 1996;1(1):30–46. doi: 10.1037/1082-989X.1.1.30
38. Mall P.K., Singh P.K., Srivastav S., Narayan V., Paprzycki M., Jaworska T., Ganzha M. A comprehensive review of deep neural networks for medical image processing: Recent developments and future opportunities. *Healthc. Anal. (N.Y.)*. 2023;4(1):100216. doi: 10.1016/j.health.2023.100216
39. Ferreira A., Jesus T., Puladi B., Kleesiek J., Alves V., Egger J. Improved multi-task brain tumour segmentation with synthetic data augmentation. Published online December 2, 2024. doi: 10.48550/arXiv.2411.04632
40. Roy S., Koehler G., Ulrich C., Baumgartner M., Petersen J., Isensee F., Jäger P.F., Maier-Hein K.H. MedNeXt: transformer-driven scaling of convnets for medical image segmentation. In: *Lecture Notes in Computer Science*. Cham: Springer, 2023. P. 405–415. doi: 10.1007/978-3-031-43901-8_39

Сведения об авторах:

Никишев Иван Олегович, ORCID: 0009-0009-2280-9170, e-mail: nkshv2@gmail.com
Сергеев Глеб Сергеевич, к.м.н., ORCID: 0000-0003-3558-810X, e-mail: dr.gssergeev@gmail.com
Верещагин Владислав Юрьевич, к.т.н., ORCID: 0000-0002-1344-4888, e-mail: slavaver@ya.ru
Кривошапкин Алексей Леонидович, д.м.н., проф., ORCID: 0000-0003-0789-8039, e-mail: alkr01@yandex.ru

Information about the authors:

Ivan O. Nikishev, ORCID: 0009-0009-2280-9170, e-mail: nkshv2@gmail.com
Gleb S. Sergeev, candidate of medical sciences, ORCID: 0000-0003-3558-810X, e-mail: dr.gssergeev@gmail.com
Vladislav Yu. Vereshchagin, candidate of technical sciences, ORCID: 0000-0002-1344-4888, e-mail: slavaver@ya.ru
Alexey L. Krivoshapkin, doctor of medical sciences, professor, ORCID: 0000-0003-0789-8039, e-mail: alkr01@yandex.ru

Поступила в редакцию 01.08.2025
После доработки 15.09.2025
Принята к публикации 12.11.2025

Received 01.08.2025
Revision received 15.09.2025
Accepted 12.11.2025