

<https://doi.org/10.21869/2223-1536-2024-14-3-104-120>



УДК 004.93

Анализ эффективности применения архитектуры U-net для классификации и сегментации глиомы на МРТ-снимках

А. В. Киселев¹ ✉, Е. А. Кулешова¹, М. О. Таныгин¹,
Д. Р. Дерябин¹, И. А. Халин¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: kiselevalexey1990@gmail.com

Резюме

Цель исследования – анализ эффективности применения нейросетевой архитектуры U-net в системах поддержки принятия врачебных решений для диагностики глиомы, а также сегментации пораженных ею областей головного мозга на МРТ-снимках.

Методы. Для проведения экспериментальных исследований был сформирован набор данных для обучения и проведена нормализация данных. Выполнена программная реализация нейросетевой архитектуры U-Net с применением фреймворка Keras на языке программирования Python. Проведено обучение нейросетевой модели.

Результаты. Проведен ряд экспериментов, в ходе которых были получены матрицы ошибок и классификации, проведена оценка эффективности классификации, обученной нейросетевой модели по классам «Опухоль» и «Без опухоли» с помощью таких метрик, как Recall, Precision и F1-мера, проведена оценка качества сегментации пораженных глиомой областей на тестовом наборе данных. Качество сегментации оценивалось с использованием метрики IoU, отражающей отношения площадей ограничительных рамок и применяемой для оценки точности пространственного соответствия предсказанных сегментированных областей, выделенных на масках. Исходя из результатов тестирования нейросетевой модели при решении задачи сегментации областей головного мозга, пораженных глиомой, было получено среднее значение метрики IoU, равное 0,812, что является приемлемым результатом.

Заключение. Результаты тестирования показали, что нейросетевая модель на основе архитектуры U-net способна эффективно диагностировать наличие глиомы с приемлемыми значениями метрик качества классификации и сегментации, что указывает на возможность применения данной нейросетевой модели в системах поддержки принятия врачебных решений для диагностики глиомы, а также ее сегментации на МРТ-снимках. Однако целесообразной является доработка данной нейросетевой модели для уменьшения числа ложноотрицательных результатов классификации, что является критически важным в медицинской диагностике.

Ключевые слова: глиома; МРТ-снимки; нейросетевая модель; нейросетевая архитектура; U-net; классификация; сегментация.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Анализ эффективности применения архитектуры U-net для классификации и сегментации глиомы на МРТ-снимках / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин, Д. Р. Дерябин, И. А. Халин // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 3. С. 104–120. <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>

Поступила в редакцию 11.07.2024

Подписана в печать 08.08.2024

Опубликована 30.09.2024

Analysis of the effectiveness of using U-net architecture for classification and segmentation of glioma in MRI images

Alexey V. Kiselev¹ ✉, Elena A. Kuleshova¹, Maxim O. Tanygin¹,
Denis R. Deryabin¹, Igor A. Khalin¹

² Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: kiselevalexey1990@gmail.com

Abstract

The purpose of the research is to analyze the efficiency of the U-net neural network architecture in decision support systems for glioma diagnostics and segmentation of brain areas affected by it on MRI images.

Methods. To conduct experimental studies, a training dataset was generated and the data was normalized. A software implementation of the U-Net neural network architecture was performed using the Keras framework in the Python programming language. The neural network model was trained.

Results. A series of experiments were conducted, during which error and classification matrices were obtained, the efficiency of classification of the trained neural network model for the "Tumor" and "No tumor" classes was assessed using metrics such as Recall, Precision and F1-measure, and the quality of segmentation of glioma-affected areas on the test data set was assessed. The quality of segmentation was assessed using the IoU metric, which reflects the ratio of the areas of the bounding boxes and is used to assess the accuracy of the spatial correspondence of the predicted segmented areas highlighted on the masks. Based on the results of testing the neural network model in solving the problem of segmenting brain areas affected by glioma, the average value of the IoU metric was 0.812, which is an acceptable result.

Conclusion. The testing results showed that the neural network model based on the U-net architecture is able to effectively diagnose the presence of glioma with acceptable values of the classification and segmentation quality metrics, which indicates the possibility of using this neural network model in medical decision support systems for glioma diagnostics, as well as its segmentation on MRI images. However, it is advisable to refine this neural network model to reduce the number of false negative classification results, which is critically important in medical diagnostics.

Keywords: glioma; MRI images; neural network model; neural network architecture; U-net; classification; segmentation.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Kiselev A.V., Kuleshova E.A., Tanygin M.O., Deryabin D.R., Khalin I.A. Analysis of the effectiveness of using U-net architecture for classification and segmentation of glioma in MRI images. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2024;14(3):104–120. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>

Received 11.07.2024

Accepted 08.08.2024

Published 30.09.2024

Введение

Глиомы представляют собой гетерогенную группу первичных опухолей центральной нервной системы (ЦНС), происходящих из прогениторных клеток глиии. Эти опухоли могут быть доброкачественными или злокачественными и классифицируются в зависимости от типа глиальных клеток, из которых они происходят (астроцитомы, олигодендроглиомы, эпендимомы и т. д.), а также степени злокачественности по шкале ВОЗ (от I до IV) [1]. Глиомы могут вызывать различные неврологические симптомы, такие как головные боли, судороги, когнитивные нарушения и двигательные расстройства, в зависимости от их локализации и размера. Диагностика глиом включает нейровизуализационные методы (МРТ, КТ) и биопсию, а лечение может включать хирургическое вмешательство, радиотерапию и химиотерапию [2]. Данный вид опухолей является наиболее распространённым типом злокачественных первичных опухолей ЦНС у взрослых. Ежегодная заболеваемость глиомами составляет около 6 случаев на 100 000 человек в мире. Традиционно эти опухоли классифицировались морфологически на основе их гистопатологических характеристик, как и другие опухоли [3].

Глиомы низкой степени злокачественности, классифицируемые как глиомы I степени, составляют приблизительно 5-6% среди всех глиальных опухолей, с заболеваемостью 0,37 случая на 100000 населения ежегодно. Эти

опухоли чаще всего диагностируются у детей, составляя 67% случаев, с преимущественным поражением мозжечка, оптических нервов, хиазмы, таламуса, базальных ганглиев и стволовых структур. Заболеваемость достигает максимума в первые две декады жизни, причём пилоидная астроцитома является самой распространённой глиальной опухолью среди детей в возрасте от 0 до 14 лет, составляя 21% от всех диагностированных случаев [4]. Глиомы высокой степени злокачественности, классифицируемые как III-IV степени, включают анапластическую астроцитому, анапластическую олигодендроглиому и мультиформную глиобластому, глиосаркому. Эти опухоли являются наиболее часто встречающимися злокачественными новообразованиями головного мозга у взрослых, составляя 60-70% всех случаев [5].

Заболеваемость злокачественными глиомами проявляется двумя пиками. Первый пик приходится на возраст от 0 до 4 лет, когда опухоли ЦНС занимают второе место среди всех злокачественных новообразований детского возраста, составляя 14-20% и уступая только лимфомам и лейкозам. Второй пик заболеваемости наступает в возрасте от 35 до 75 лет, когда злокачественные глиомы становятся третьей наиболее частой причиной смерти от онкологических заболеваний среди мужчин и четвёртой среди женщин в экономически развитых странах. Это подчеркивает необходимость развития эффективных стратегий

диагностики и лечения данных опухолей, особенно в раннем возрасте и взрослом периоде жизни [6].

Согласно данным Американской ассоциации исследования опухолей мозга, пятилетний показатель выживаемости при глиоме значительно различается в зависимости от степени злокачественности и других факторов и колеблется от 5% до 95% (табл. 1).

Магнитно-резонансная томография (МРТ) является одним из основных инструментов для диагностики опухолей ЦНС. МРТ обеспечивает детальное изображение мягких тканей мозга,

позволяя с высокой точностью оценить размеры, форму и точное расположение опухоли, а также её отношение к критически важным анатомическим структурам. Это особенно важно для планирования хирургического вмешательства и других видов лечения. В контексте первичной диагностики МРТ является предпочтительным выбором, что связано с высокой точностью метода при визуализации мягких тканей мозга и отсутствием ионизирующего излучения, что делает метод безопасным для пациентов [8].

Таблица 1. Пятилетний показатель выживаемости при глиоме в зависимости от степени злокачественности, % [7]

Table 1. Five-year survival rate for glioma depending on the grade of malignancy, % [7]

Степень злокачественности	Пятилетний показатель выживаемости
Глиомы I степени (пилочитарные астроцитомы)	95
Глиомы II степени (диффузные астроцитомы)	40–50
Глиомы III степени (анapластические астроцитомы)	25–30
Глиомы IV степени (мультиформная глиобластома)	5–10

Глиомы часто диагностируются на поздних стадиях, когда лечение уже может быть неэффективным или вовсе невозможным. Поэтому диагностика именно на ранних стадиях заболевания играет ключевую роль в положительном исходе лечения. В силу ограниченной доступности высококвалифицированных специалистов для анализа МРТ-снимков, в том числе связанные с территориальными особенностями нашей страны, возникает актуальная потребность в системах поддержки принятия врачебных

решений для диагностики опухолей ЦНС на ранних стадиях [9]. Применение алгоритмов машинного обучения может автоматизировать процессы интерпретации изображений и снизить вероятность ошибок [10]. Это может помочь справиться с недостатком специалистов и повысить доступность качественной диагностики для населения, не зависящей от географического положения или экспертного опыта отдельных врачей.

В работе [11] авторы предложили использовать сверточную нейронную

сеть (СНС) для классификации степеней глиом (I, II, III и IV) и различения глиом низкой степени злокачественности от глиом высокой степени злокачественности, достигнув точности 71% и 96% соответственно. В работе [12] была разработана комбинация СНС и генетического алгоритма для классификации степеней глиом (II, III и IV) с точностью 90,9%. В работе [13] авторы исследовали метод трансферного обучения для оценки степени злокачественности глиом, получив тестовую точность более 90%.

Таким образом, внедрение СНС и связанных с ними методов машинного обучения существенно продвигает область диагностики и классификации глиом, открывая новые перспективы для разработки более точных и персонализированных инструментов лечения пациентов [5].

Материалы и методы

U-Net представляет собой нейросетевую модель (НМ) на базе архитектуры СНС. Архитектура U-Net не имеет полностью связанных слоев, а состоит из так называемой карты признаков между входными и выходными слоями, а также ядра свертки для получения и укрепления признаков начального объекта [14]. Еще одной отличительной особенностью можно выделить саму структуру, которая представляет собой своеобразный метод кодера-декодера, что позволяет эффективно отображать трехканальные снимки МРТ в одноканальные маски

сегментации. Кодер извлекает особенности из входных данных, а декодер, в свою очередь, реконструирует маски, выделяя область отклонения. Этот алгоритм действий сохраняет всю необходимую информацию и детали [15].

Обычная архитектура автокодировщика уменьшает размер входной информации, а затем и следующих слоев. Затем начинается декодирование, изучается представление линейного объекта, и размер кадра постепенно увеличивается. Проблема в том, что он сжимает входные данные линейным образом, что предотвращает передачу всех имеющихся функций.

В НМ U-Net для решения данной проблемы используется деконволюция. Деконволюция выполняется на стороне декодера, что позволяет избежать проблемы «узких мест», возникающей в архитектуре автоматического кодирования, и, таким образом, потери функций.

Рассмотрим архитектуру U-Net (рис. 1). Она состоит из двух составляющих частей – сужающейся (энкодер) и расширяющейся (декодер). Энкодер представляет собой стек сверточных слоев, которые постепенно уменьшают размеры входного изображения, извлекая при этом высокоуровневые признаки. Каждый сверточный блок обычно состоит из двух последовательных сверточных слоев с последующей операцией пулинга (например, максимальное пулинг), которая уменьшает размеры изображения вдвое. Декодер состоит из транспонированных сверточных слоев

(или операций пространственной интерполяции), которые постепенно увеличивают размеры изображения, восстанавливая пространственную разрешающую способность. Каждый блок декодера

соединен с соответствующим блоком энкодера с помощью пропускающих соединений (skip connections), что позволяет сохранять детальные пространственные признаки [16].




Рис. 1. Архитектура U-Net

Fig. 1. U-Net Architecture

Для обучения НМ требуются высококачественные и точно аннотированные изображения. Создание собственного массива данных без соответствующего опыта в медицинской аннотации может привести к неточностям в обучающих данных, что негативно скажется на работе модели [17]. Поэтому для обучения был использован набор данных The Cancer Imaging Archive (TCIA) [18], который включает в себя МРТ-снимки головного мозга и размеченные маски сегментации глиом для 110 пациентов. Набор данных состоит из 3929 изобра-

жений, среди которых МРТ-снимки с аннотированными областями злокачественных образований и МРТ-снимки полностью здоровых пациентов, которые имеют полностью черную маску.

При формировании набора данных для обучения 3182 изображения использовались в обучающей выборке, 657 изображений использовались для процесса валидации и 90 изображений использовалось для тестирования модели. Рассмотрим распределение набора данных (рис. 2). Все изображения прошли тщательную предварительную проверку на

соответствие установленным критериям качества и релевантности, чтобы

минимизировать риск необходимости последующего переобучения модели.




Рис. 2. Распределение набора данных

Fig. 2. Distribution of the data set

Все изображения из набора данных были преобразованы в формат, подходящий для НМ. Этот процесс включал нормализацию данных и необходимое изменение размеров изображений.

Программная реализация модели U-Net была осуществлена с применением фреймворка Keras на языке программирования Python. Условно НМ можно разделить на две части – энкодер и декодер.

В качестве функции активации последовательных сверточных слоев вместо стандартной функции ReLU использовалась Leaky ReLU.

Принцип работы функции активации ReLU можно описать по формуле

$$\text{ReLU}(x) = \max(0, x), \quad (1)$$

где x – входное значение.

Функцию активации Leaky ReLU можно описать по формуле

$$f(x) = \max(ax, x), \quad (2)$$

где x – входное значение; a – любое небольшое значение (обычно около 0,01).

Основным отличием этих двух функций активации является то, что Leaky ReLU позволяет пропускать не-большой градиент при нулевом или отрицательном входе, вместо того чтобы

полностью обнулять его, как это делает ReLU. Использование в качестве функции активации Leaky ReLU позволило ускорить процесс обучения, обеспечивая более эффективное и быстрое достижение оптимальных весов в сети, по сравнению с функцией активацией ReLU. Также Leaky ReLU может способствовать лучшему распространению градиентов по сети во время обратного распространения ошибки, что способствует более точному выделению границ опухолей при сегментации [19].

Энкодер состоит из 4 сверточных блоков (conv_block), которые обрабатывают изображения. При этом каждый из блоков содержит слои Conv2D, за которыми следуют пакетная нормализация, активация Leaky ReLU и операции Max Pooling 2D. Каждый сверточный блок применяет фильтры к изображению, поданному на вход, или применяется карта признаков, если данные уже проходят более, чем один блок. Далее происходит нормализация (BatchNormalization), необходимая для стабилизации и ускорения процесса обучения, а также функция активации Leaky ReLU для добавления нелинейности в модель и реализации обработки более сложных данных [20].

Между кодером и декодером устанавливается связь с уровнями Conv2D, пакетной нормализацией и активацией Leaky ReLU для оптимизации потока информации. В разделе декодера применяются 4 блока повышающей дискретизации, каждый из которых содержит слои Conv2DTranspose для повышающей

дискретизации, конкатенации для остаточных соединений и ранее упомянутые сверточные блоки. Остаточные соединения позволяют НМ сохранять функции высокого разрешения от кодера при прохождении через декодер.

В декодирующей части используется четыре блока повышающей дискретизации, каждый из которых включает в себя слои Conv2DTranspose для увеличения размерности данных. Эти слои фактически выполняют обратную операцию по сравнению с пулингом, увеличивая размеры изображений. Для восстановления исходных пространственных размерностей и деталей изображений в блоках декодера также применяется операция конкатенации, которая объединяет карты признаков из соответствующих слоёв энкодера через пропускные (остаточные) соединения. Эти соединения играют ключевую роль, поскольку позволяют сохранить информацию о высоко-разрешенных признаках, которая могла бы быть потеряна на более глубоких уровнях сети.

Выходная часть модели состоит из слоя Conv2D, за которым следует пакетная нормализация, активация Leaky ReLU и последний слой Conv2D.

Параметры скорости обучения и функции потерь были точно настроены в ходе нескольких сеансов обучения, в результате чего была выбрана скорость обучения 0,0003 и среднеквадратическая ошибка в качестве функции потерь.

Для уменьшения показателя несоответствия маски сегментации и

действительными масками истинности в процессе обучения была проведена корректировка весов. Временные затраты на обучение НМ с помощью CPU составили 8 часов, что объясняется специфическими требованиями архитектуры U-Net к процессу обновления весов.

График, приведенный на рисунке 3, визуализирует изменения в потерях при обучении и проверке на разных эпохах,

представляя данные о производительности и сходимости модели. Из графического представления изменения потерь видно, что после резкого снижения на начальных этапах кривая потерь выходит на плато, указывая на достижение моделью стабильного состояния, при котором дальнейшее обучение не приведет к значительному улучшению показателей.




Рис. 3. График потерь относительно проведенных эпох обучения

Fig. 3. Graph of losses relative to the training epochs conducted

Результаты и их обсуждение

Была проведена оценка эффективности классификации, обученной НМ по классам «Опухоль» и «Без опухоли», а также оценка качества сегментации пораженных глиомой областей на тестовом наборе данных.

Качество сегментации оценивалось с использованием отношения площадей ограничительных рамок (Intersection over Union, IoU) (3) – метрики, применяемой для оценки точности пространственного соответствия предсказанных

сегментированных областей, выделенных на масках [21].

$$IoU = \frac{S(A \cap B)}{S(A \cup B)}, \quad (3)$$

где A и B – предсказанная ограничительная рамка и настоящая ограничительная рамка соответственно. $IoU = 0$, если A и B не пересекаются, $IoU = 1$ в случае идеального наложения [22].

На рисунках 4 и 5 продемонстрированы результаты сегментации областей головного мозга, пораженных глиомой, на МРТ-снимках для классов «Опухоль» и «Без опухоли» соответственно.




Рис. 4. Результаты сегментации пораженных глиомой областей головного мозга на МРТ-снимках для класса «Опухоль»

Fig. 4. Results of segmentation of brain areas affected by glioma on MRI images for the "Tumor" class




Рис. 5. Результаты сегментации пораженных глиомой областей головного мозга на МРТ-снимках для классов «Без опухоли»

Fig. 5. Results of segmentation of brain regions affected by glioma in MRI images for the "No tumor" classes

На рисунке 6 представлены график распределения классов в тестовом наборе данных и график распределения результатов классификации НМ, при этом средний показатель отношения площадей ограничительных рамок (IoU) при сегментации областей головного мозга, пораженных глиомой, составил 0,812, что является приемлемым результатом.

Матрица ошибок (рис. 7) отображает результаты классификации для

тестового набора данных, состоящего из 90 МРТ-снимков, и показывает следующие результаты: 25 случаев (True Positive (TP)) – модель верно предсказала наличие глиомы на изображении, 57 случаев (True Negative (TN)) – модель правильно предсказала, что опухоль отсутствует на снимке, и 8 случаев, когда модель не могла верно определить отсутствие, и наличие глиомы – 7 (False Negatives (FN)) и 1 (False Positive (FP)) примеров соответственно.




Рис. 6. График распределения классов в тестовом наборе данных и график распределения результатов классификации НМ

Fig. 6. Graph of class distribution in the test dataset and graph of the distribution of the classification results of the NM




Рис. 7. Матрица ошибок

Fig. 7. Error matrix

На основе полученных данных о количестве ошибок первого и второго рода была проведена оценка качества классификации с помощью метрик Recall, Precision и F1-меры.

Метрика оценки качества классификации Recall описывается по (4):

$$recall = \frac{TP}{TP + FN}. \quad (4)$$

Метрика оценки качества классификации Precision описывается по (5):

$$Precision = \frac{TP}{TP + FP}. \quad (5)$$

Метрика оценки качества классификации F1-мера описывается по (6):

$$F1 = 2 \cdot \frac{Precision \cdot recall}{Precision + recall}. \quad (6)$$

Также для полноты визуализации оценки качества классификации НМ была построена матрица классификации, которая наглядно отражает значения данных метрик по классам «Опухоль» и «Без опухоли» (рис. 8).




Рис. 8. Матрица классификации

Fig. 8. Classification matrix

Выводы

В статье представлены результаты анализа эффективности использования нейросетевой архитектуры U-net для диагностики глиомы, а также сегментации пораженных ею областей головного мозга на МРТ-снимках.

Для проведения экспериментальных исследований был сформирован набор

данных для обучения и проведена нормализация данных. Выполнена программная реализация нейросетевой архитектуры U-Net с применением фреймворка Keras на языке программирования Python. Проведено обучение НМ.

Проведен ряд экспериментов, в ходе которых были получены матрицы ошибок и классификации, что позволило

провести оценку качества классификации НМ с помощью таких метрик, как Recall, Precision и F1-мера. Исходя из результатов тестирования НМ при решении задачи сегментации областей головного мозга, пораженных глиомой, было получено среднее значение метрики качества сегментации (IoU), равное 0,812, что является приемлемым результатом.

Результаты тестирования показали, что НМ эффективно диагностирует наличие глиомы, с приемлемыми

значениями метрик качества классификации и сегментации, что указывает на возможность применения данной НМ в системах поддержки принятия врачебных решений для диагностики глиомы, а также ее сегментации на МРТ-снимках. Однако целесообразной является доработка данной НМ для уменьшения числа ложноотрицательных результатов классификации, что является критически важным в медицинской диагностике.

Список литературы

1. Epidemiology, risk factors, and prognostic factors of gliomas / A. Pellerino [et al.] // *Clinical and Translational Imaging*. 2022. Vol. 10. P. 467–475. <https://doi.org/10.1007/s40336-022-00489-6>
2. Malignant Glioma / L. Wang [et al.] // *Advances in experimental medicine and biology*. 2023. Vol. 1405. P. 1–30. https://doi.org/10.1007/978-3-031-23705-8_1
3. Patil P., Giridhar P. Epidemiology and Demography of Brain Tumors // *Evidence based practice in Neuro-oncology*. Springer, 2021. P. 3–7. https://doi.org/10.1007/978-981-16-2659-3_1
4. Pediatric-type low-grade gliomas in adolescents and young adults-challenges and emerging paradigms / J. Bennett [et al.] // *Child's Nervous System*. 2024. P. 1–11. <https://doi.org/10.1007/s00381-024-06449-x>
5. Improved Glioma Grading Using Deep Convolutional Neural Networks / S. Gutta, J. Acharya, M. S. Shiroishi, D. Hwang, K. S. Nayak // *AJNR. Am. J. Neuroradiol.* 2021. N 42(2). P. 233–239. <https://doi.org/10.3174/ajnr.A6882>
6. Шевченко Т. А. Современные проблемы лечения глиом головного мозга высокой степени злокачественности // *Вестник Российского научного центра рентгенорадиологии Минздрава России*. 2021. № 3. С. 10–12.
7. CBTRUS Statistical Report: American Brain Tumor Association & NCI Neuro-Oncology Branch Adolescent and Young Adult Primary Brain and Other Central Nervous System Tumors Diagnosed in the United States in 2016-2020 / M. Price [et al.] // *Neuro-Oncology*. 2024. N 26. P. 1–53. <https://doi.org/10.1093/neuonc/noae047>
8. Jin Y., Peng H., Peng J. Brain glioma localization diagnosis based on MRI // *World neurosurgery*. 2021. N 149. P. 325–332. <https://doi.org/10.1016/j.wneu.2020.09.113>
9. Алгоритмы мониторинга эффективности терапевтических и реабилитационных процедур по показателям клинического анализа крови в системе поддержки принятия врачебных решений / А. В. Бутусов, А. В. Киселев, Е. В. Петрунина [и др.] // *Известия*

Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 1. С. 170–190. <https://doi.org/10.21869/2223-1536-2023-13-1-170-190>

10. Томакова Р. А., Дзюбин И. А., Брежнев А. В. Метод и алгоритм обучения сверточной нейронной сети, предназначенной для интеллектуальной системы распознавания меланомы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 1. С. 65–83. <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>

11. Automated glioma grading on conventional MRI images using deep convolutional neural networks / Y. Zhuge [et al.] // Medical Physics. 2020. N 47 (7). P. 3044–3053. <https://doi.org/10.1002/mp.14168>

12. Anaraki A. K., Ayati M., Kazemi F. Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms // Biocybernetics and Biomedical Engineering. 2019. N 39. P. 63–74.

13. Intelligent Glioma Grading Based on Deep Transfer Learning of MRI Radiomic Features / C. M. Lo [et al.] // Applied Sciences. 2019. N 9 (22). P. 4926. <https://doi.org/10.3390/app9224926>

14. Medical Image Segmentation Review: The Success of U-Net / R. Azad [et al.] // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2024. P. 1–20. <https://doi.org/10.1109/TPAMI.2024.3435571>

15. Pan J. Image Segmentation Based On U-Net and Adjusted U-Nets // Highlights in Science, Engineering and Technology. 2024. N 85. P. 316–327. <https://doi.org/10.54097/accm2w81>

16. Bangul K., Hajira F., Ayatullah Q. Drawbacks of Artificial Intelligence and Their Potential Solutions in the Healthcare Sector // Biomed Mater & Devices. 2023. Vol. 1. P. 731–738. <https://doi.org/10.1007/s44174-023-00063-2>

17. TransDeepLab: Convolution-Free Transformer-Based DeepLab v3+ for Medical Image Segmentation / R. Azad [et al.] // Predictive Intelligence in Medicine: 5th International Workshop, PRIME 2022, Held in Conjunction with MICCAI 2022. Singapore: Springer, 2022. P. 91–102. https://doi.org/10.1007/978-3-031-16919-9_9

18. The PRISM semantic cohort builder: a novel tool to search and access clinical data in TCIA imaging collections / J. Bona [et al.] // Physics in Medicine & Biology. 2022. N 68 (1). P. 014003. <https://doi.org/10.1088/1361-6560/ac9d1d>

19. Increasing the Versatility of Leaky ReLU Using a Nonlinear Function / P. Bedi [et al.] // Advanced Machine Intelligence and Signal Processing. Springer, 2022. P. 433–442. https://doi.org/10.1007/978-981-19-0840-8_32

20. Segmentation and Estimation of Fetal Biometric Parameters using an Attention Gate Double U-Net with Guided Decoder Architecture / S. Degala [et al.] // Computers in Biology and Medicine. 2024. N 180. P. 109000. <https://doi.org/10.1016/j.compbiomed.2024.109000>

21. Киселев А. В., Брусенцев Н. С., Кулешова Е. А. Анализ эффективности применения двухэтапных нейросетевых моделей для раннего обнаружения лесных пожаров //

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 8–23. <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>

22. Stodt J., Reich C., Clarke N. Unified Intersection Over Union for Explainable Artificial Intelligence // *Intelligent Systems and Applications: Proceedings of the 2023 Intelligent Systems Conference (IntelliSys)*. Springer, 2024. P. 758–770. https://doi.org/10.1007/978-3-031-47724-9_50

References

1. Pellerino A., et al. Epidemiology, risk factors, and prognostic factors of gliomas. *Clinical and Translational Imaging*. 2022;10:467–475. <https://doi.org/10.1007/s40336-022-00489-6>

2. Wang L., et al. Malignant Glioma. *Advances in experimental medicine and biology*. 2023;1405:1–30. https://doi.org/10.1007/978-3-031-23705-8_1

3. Patil P., Giridhar P. Epidemiology and Demography of Brain Tumors. In: *Evidence based practice in Neuro-oncology*. Springer; 2021. P. 3–7. https://doi.org/10.1007/978-981-16-2659-3_1

4. Bennett J., et al. Pediatric-type low-grade gliomas in adolescents and young adults—challenges and emerging paradigms. *Child's Nervous System*. 2024. P. 1–11. <https://doi.org/10.1007/s00381-024-06449-x>

5. Gutta S., Acharya J., Shiroishi M.S., Hwang D., Nayak K.S. Improved Glioma Grading Using Deep Convolutional Neural Networks. *AJNR. Am. J. Neuroradiol.* 20214;(42):233–239. <https://doi.org/10.3174/ajnr.A6882>

6. Shevchenko T.A. Modern problems of treatment of gliomas of the brain of a high degree of malignancy. *Vestnik Rossiiskogo nauchnogo tsentra rentgenoradiologii Minzdrava Rossii = Bulletin of the Russian Scientific Center for X-ray Radiology of the Ministry of Health of the Russian Federation*. 2021;(3):10–12. (In Russ.)

7. Price M., et. al. CBTRUS Statistical Report: American Brain Tumor Association & NCI Neuro-Oncology Branch Adolescent and Young Adult Primary Brain and Other Central Nervous System Tumors Diagnosed in the United States in 2016–2020. *Neuro-Oncology*. 2024;(26):1–53. <https://doi.org/10.1093/neuonc/noae047>

8. Jin Y., Peng H., Peng J. Brain glioma localization diagnosis based on MRI. *World Neurosurgery*. 2021;(149):325–332. <https://doi.org/10.1016/j.wneu.2020.09.113>

9. Butusov A.V., Kiselev A.V., Petrunina E.V., et al. Algorithms for monitoring the effectiveness of therapeutic and rehabilitation procedures based on indicators of clinical blood analysis in the medical decision support system. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2023;13(1):170–190. (In Russ.) <https://doi.org/10.21869/2223-1536-2023-13-1-170-190>

10. Tomakova R.A., Dzyubin I.A., Brezhnev A.V. Method and algorithm of training a convolutional neural network designed for an intelligent system of melanoma cognition. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2022;12(1):65–83 (In Russ.). <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>
11. Zhuge Y., et. al. Automated glioma grading on conventional MRI images using deep convolutional neural networks. *Medical Physics*. 2020; (47):3044–3053. <https://doi.org/10.1002/mp.14168>
12. Anaraki A.K., Ayati M., Kazemi F. Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms // *Biocybernetics and Biomedical Engineering*. 2019;39:63–74.
13. Lo C. M., et al. Intelligent Glioma Grading Based on Deep Transfer Learning of MRI Radiomic Features. *Applied Sciences*. 2019; (9):4926. <https://doi.org/10.3390/app9224926>
14. Azad R., et al. Medical Image Segmentation Review: The Success of U-Net. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2024. P. 1–20. <https://doi.org/10.1109/TPAMI.2024.3435571>
15. Pan J. Image Segmentation Based On U-Net and Adjusted U-Nets. *Highlights in Science, Engineering and Technology*. 2024;85:316–327. <https://doi.org/10.54097/acm2w81>
16. Bangul K., Hajira F., Ayatullah Q. Drawbacks of Artificial Intelligence and Their Potential Solutions in the Healthcare Sector. *Biomed Mater & Devices*. 2023;1:731–738. [10.1007/s44174-023-00063-2](https://doi.org/10.1007/s44174-023-00063-2)
17. Azad R., et al. TransDeepLab: Convolution-Free Transformer-Based DeepLab v3+ for Medical Image Segmentation. In: *Predictive Intelligence in Medicine: 5th International Workshop, PRIME 2022, Held in Conjunction with MICCAI 2022*. Singapore: Springer, 2022. P. 91–102. https://doi.org/10.1007/978-3-031-16919-9_9
18. Bona J., et al. The PRISM semantic cohort builder: a novel tool to search and access clinical data in TCIA imaging collections. *Physics in Medicine & Biology*. 2022; (68):014003. <https://doi.org/10.1088/1361-6560/ac9d1d>
19. Bedi P., et al. Increasing the Versatility of Leaky ReLU Using a Nonlinear Function. In: *Advanced Machine Intelligence and Signal Processing*. Springer; 2022. P. 433–442. https://doi.org/10.1007/978-981-19-0840-8_32
20. Degala S., et. al. Segmentation and Estimation of Fetal Biometric Parameters using an Attention Gate Double U-Net with Guided Decoder Architecture. *Computers in Biology and Medicine*. 2024;(180). <https://doi.org/10.1016/j.compbimed.2024.109000>
21. Kiselev A.V., Brusentsev N.S., Kuleshova E.A. Analysis of the effectiveness of using two-stage neural network models for early detection of forest fires. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(1):8–23. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>

22. Stodt J., Reich C., Clarke N. Unified Intersection Over Union for Explainable Artificial Intelligence. In: *Intelligent Systems and Applications: Proceedings of the 2023 Intelligent Systems Conference (IntelliSys)*. Springer; 2024. P. 758–770. https://doi.org/10.1007/978-3-031-47724-9_50

Информация об авторах / Information about the Authors

Киселев Алексей Викторович, кандидат технических наук, доцент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281

Alexey V. Kiselev, Candidate of Sciences (Engineering), Associate Professor of the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281

Кулешова Елена Александровна, кандидат технических наук, доцент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Elena A. Kuleshova, Candidate of Sciences (Engineering), Associate Professor of the Department of Information Security, Southwest State University, Kursk, Russian Federation, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Таныгин Максим Олегович, доктор технических наук, доцент, профессор кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

Maxim O. Tanygin, Doctor of Sciences (Engineering), Associate Professor, Professor of the Department of Information Security, Southwest State University, Kursk, Russian Federation, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

Дерябин Денис Романович, студент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: vt.swsu@yandex.ru, ORCID: 0009-0004-4102-0005

Denis R. Deryabin, Student of the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation, e-mail: vt.swsu@yandex.ru, ORCID: 0009-0004-4102-0005

Халин Игорь Алексеевич, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: yur-khalin@yandex.ru, ORCID: 0009-0004-1205-2139

Igor A. Khalin, Post-Graduate Student of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: yur-khalin@yandex.ru, ORCID: 0009-0004-1205-2139