

Классификация аномалий головного мозга, выраженных на снимках МРТ, с использованием дескрипторов признаков HOG и нейронных сетей

Я. А. Низамли[✉], А. Ю. Филатов

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

[✉]yanizamli@stud.etu.ru

Аннотация. Представлен подход, направленный на обнаружение типов аномалий головного мозга на МРТ-изображениях, который обеспечивает высокую производительность и простоту дизайна. Разработанная модель предлагает извлекать вручную созданные числовые признаки из МРТ-изображений с помощью точно настроенного алгоритма гистограммы ориентированных градиентов (HOG). Полученные признаки подвергаются оптимизации размерности применением анализа главных компонент (PCA), прежде чем они будут переданы в 6-слойную специализированную нейронную сеть, обученную для выполнения задачи идентификации опухоли. Кроме того, исследуется возможность выполнения аугментации в пространстве признаков с использованием метода синтетической перевыборки меньшинства (SMOTE). Предложенный подход показал высокую точность 99.65 % и оценку F1 99.64 %, что превосходит многие результаты в современной литературе.

Ключевые слова: МРТ, опухоли головного мозга, HOG, нейронный классификатор, SMOTE

Для цитирования: Низамли Я. А., Филатов А. Ю. Классификация аномалий головного мозга, выраженных на снимках МРТ, с использованием дескрипторов признаков HOG и нейронных сетей // Изв. СПбГЭТУ «ЛЭТИ». 2025. Т. 18, № 2. С. 35–48. doi: 10.32603/2071-8985-2025-18-2-35-48.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Original article

Classification of Brain Abnormalities Expressed in MRI Images Using HOG Feature Descriptors and Neural Networks

Ya. A. Nizamli[✉], A. Yu. Filatov

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

[✉]yanizamli@stud.etu.ru

Abstract. An approach aimed at detecting types of brain abnormalities in MRI images is presented, which provides high performance and simplicity of design. The developed model proposes to extract handcrafted numerical features from MRI images using a fine-tuned histogram of oriented gradients algorithm. The obtained features undergo dimensionality optimization by applying principal component analysis before being passed to a 6-layer custom neural network that is trained to perform the tumor identification task. In addition, our work investigates the feasibility of performing augmentation in the feature space using the synthetic minority oversampling technique. The proposed approach achieved a high accuracy of 99.65 % and an F1-score of 99.64 %, superior to many works in recent literature.

Keywords: MRI, brain tumors, HOG, Neural classifier, SMOTE

For citation: Nizamli Ya. A., Filatov A. Yu. Classification of Brain Abnormalities Expressed in MRI Images Using HOG Feature Descriptors and Neural Networks // LETI Transactions on Electrical Engineering & Computer Science. 2025. Vol. 18, no. 2. P. 35–48. doi: 10.32603/2071-8985-2025-18-2-35-48.

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

Введение. Опухоль определяется как аномальный рост и деление клеток, которые могут образовываться в любой ткани или органе человеческого тела, нанося серьезный вред. Этот аномальный рост называется опухолью мозга, если он развивается в спинном или головном мозге. Опухоль мозга может быть доброкачественной или злокачественной. Первая – неаковая и характеризуется медленным ростом, в то время как вторая может агрессивно распространяться в ограниченном пространстве черепа, что приводит к значительному повреждению жизненно важных функций [1]–[3]. Сенсорные и когнитивные нарушения, судороги, головные боли, тошнота, рвота и проблемы со зрением – это распространенные симптомы, сообщаемые при возникновении опухоли мозга. Используемый подход к лечению и вероятность его успеха зависят от нескольких факторов, включая стадию и тип опухоли среди прочих [4], [5]. В зависимости от места нахождения наиболее частые опухоли мозга можно разделить на три типа: менингиома, глиома и опухоли гипофиза [2], [6]–[10]. Быстрая и высокоточная диагностика этих опухолей вносит значительный вклад в улучшение качества жизни пациентов и увеличение их средней продолжительности жизни.

Обнаружение и классификация потенциальных опухолей головного мозга в основном зависят от методов медицинской визуализации, которые могут включать магнитно-резонансную (МРТ), компьютерную (КТ) и позитронно-эмиссионную (ПЭТ) томографию. Среди доступных методов магнитно-резонансная томография представляется наилучшим и первым выбором для использования из-за ее способности генерировать изображения высокого разрешения и высокого качества внутренних структур с использованием сильных магнитных полей и радиоволн [5], [6], [11], [12]. Однако, в дополнение к требуемому времени и усилиям, все ручные методы диагностики имеют один существенный недостаток – необходимость в опытном операторе-человеке для интерпретации полученных изображений и определения патологического состояния. Чтобы преодолеть эту проблему, происходит постепенный переход к автоматизированным методам диа-

гностики на основе компьютеров, неотъемлемой частью которых стал искусственный интеллект, находящийся в состоянии непрерывного научно-исследовательского развития [3], [9], [11].

Литературный обзор. В течение нескольких лет научно-исследовательское сообщество представило множество методов, которые опираются на модели машинного обучения и глубокого обучения с целью улучшения процесса автоматизации обнаружения и классификации опухолей мозга, выраженных на изображениях МРТ. Далее представлен обширный обзор новейшей литературы, связанной с темой исследования.

В [2] для обнаружения опухолей мозга исследователи изучили использование трех предварительно обученных глубоких моделей для извлечения признаков из изображений МРТ, а затем передачи полученных признаков в полностью связанную нейронную сеть, которая выполняет задачу классификации изображений на здоровые или демонстрирующие опухоль. Модель VGG-16 достигла наивысшей точности тестирования 88.26 %, в то время как точность обучения достигла 96 %, превзойдя как InceptionV3, так и ResNet50 сети.

Чтобы отличить нормальные изображения МРТ мозга от аномальных, авторы [3] предложили извлекать вручную созданные признаки с помощью гистограммы ориентированных градиентов (HOG, Histogram of oriented gradients), а затем передавать числовое представление изображений в классификатор опорных векторных машин. Исследователи заявили, что представленная модель достигла точности 93.2 % для выполненной задачи бинарной классификации.

Исследователи в [6] представили специализированную сеть CNN (Convolutional neural network) для классификации типов опухолей мозга на изображениях МРТ. Сеть состоит из трех блоков свертки-пулинга, за которыми следует полностью связанная нейронная сеть. Разработанная модель сравнивалась с четырьмя методами извлечения признаков, а именно: с локальным двоичным шаблоном (Local binary patterns, LBP), матрицей совпадений уровней серого (Gray level co-occurrence matrices, GLCM), методом разности уровней серого (Gray level difference method, GLDM) и HARALICK, за каждым из которых следовал

классический классификатор. Предложенная модель достигла наивысшей точности среди всех оцененных методов, достигнув 93 %.

В структуре, очень похожей на предыдущую, исследователи в [7] использовали модель CNN, которая также состоит из трех блоков свертки-пулинга, за которыми следует нейронный классификатор. Эта сеть отличается от конструкции в [6] только количеством фильтров и размером предоставленных входных изображений. С использованием предложенной модели получена точность 96 % для задачи определения категории опухоли головного мозга.

Для решения той же задачи различения типов опухолей мозга исследователи в [8] разработали глубокую модель, содержащую пять сверточных слоев и четыре слоя пулинга, за которыми следует полностью связанная сеть. Признаки извлекаются из предложенной сети и передаются в классификатор SVM, который, в свою очередь, выполняет задачу классификации. Точность модели достигла 96 %, что превосходит сети AlexNet, GoogLeNet и VGG16, как заявляют авторы исследования.

Подходы ансамблевого обучения использовались в научной работе для дифференциации типов аномалий на снимках МРТ мозга. В [9] решение о классификации принимается на основе голосования группы классификаторов (XGBoost, SVM, RF), которые были обучены на признаках, извлеченных из предварительно обученной модели DenseNet169. Представленная модель достигла точности 95.10 % с оценкой F1 94 %. В [10] три CNN, идентичные по структуре и отличающиеся по функции потерь, были обучены, а затем использованы в качестве компонента извлечения признаков. В первом проведенном эксперименте признаки, извлеченные из сетей, объединяются и подаются в классификатор (SVM или KNN), в то время как во втором эксперименте признаки из каждой сети передаются отдельно в три экземпляра того же алгоритма, так что окончательное решение принимается на основе голосования большинства. Предложенный метод во втором эксперименте достиг наивысшей точности 95.6 % при использовании KNN в качестве классификатора.

В [12] исследователи разработали модель CNN, состоящую из пяти блоков свертки-пулинга, за которыми следовал глобальный средний слой пулинга и, наконец, слой SoftMax. Исследователи сообщили о получении точности обнаружения опухолей 98 %, в то время как достигнутая оценка F1 составила всего 85 %.

Исследователи в [13] представили новую модель, основанную на двух CNN, работающих параллельно для извлечения признаков из изображений МРТ. Обе сети состоят из трех блоков свертки-пулинга, которые отличаются только размером окна ядра. Выходные данные из двух сетей объединяются и затем передаются в нейронный классификатор. Для задачи мультиклассификации была зарегистрирована точность теста 97.60 %. Такая производительность была достигнута при выделении 10 % данных для тестирования, в то время как точность не превысила 96.16 % при выделении 20 %.

В [14] архитектура современной модели компьютерного зрения YOLO используется для обнаружения опухолей мозга на снимках МРТ. Модель в своей восьмой версии (YOLOv8) с использованием методов аугментации данных достигла точности (precision) 94.2 % и полноты 90.8 %. Оценку F1 можно рассчитать как гармоническое арифметическое среднее этих предоставленных метрик, и она достигла только 92.47 %.

Для сглаживания краев и удаления избыточных артефактов изображения МРТ мозга были подвергнуты процедуре обработки с использованием нейронной авторегрессионной оценки распределения (NADE) [15]. Улучшенные изображения передаются в предварительно обученную модель VGG16 для извлечения важных признаков, которые в конечном итоге подаются в нейронную классификационную сеть. Представленная модель достигла точности 96.01 %, в то время как без использования аугментации она не превысила 92.33 %.

Исследователи в [16] предложили применить процесс оптимизации к признакам, полученным при передаче изображений МРТ в предварительно обученную модель VGG19. Используемая оптимизация зависит от уменьшения размеров признаков с использованием регуляризации L1-штрафа в алгоритме логистической регрессии перед выполнением классификации через SVM с ядром RBF. Исследователи сообщили о достижении точности теста 98.53 %.

В связи с тем, что опухоли головного мозга относятся к самым смертельным видам рака, высокоточная диагностика опухолей и ее основных типов считается очень важной для сохранения жизни пациента. Как можно проследить, достаточная точность не была достигнута во всех моделях, представленных в литературе. С другой стороны, некоторые модели могут показывать обманчиво высокую точность, которая не отража-

ет реальную производительность. Это наблюдается по появлению разрыва между значением точности и другими оценочными метриками, из которых наиболее важна оценка F1. Кроме того, некоторые модели могут не достичь обобщения для тестовых выборок из-за переобучения, возникающего в результате обучения глубоких моделей с большим количеством параметров или извлечения высокоразмерных признаков и передачи их напрямую без оптимизации в алгоритмы машинного обучения. В наших исследованиях мы пытаемся преодолеть эти проблемы, и поэтому наши основные вклады заключаются в следующем:

- Предложить подход, направленный на классификацию опухолей головного мозга на снимках МРТ на основе вручную созданных числовых признаков, извлеченных с помощью точно настроенной методики HOG.

- Разработать специализированную нейронную сеть, которая обеспечит высокую точность обнаружения категорий опухолей головного мозга, сохранив при этом простоту.

- Улучшить производительность представленной модели путем внедрения автоматической аугментации в пространстве признаков с использованием синтетической пере выборки меньшинства.

- Оценить предлагаемый подход с использованием различных показателей и провести сравнение с моделями, представленными в литературе.

Материалы и методы. На рис. 1 показан рабочий процесс предлагаемого подхода для дифференциации типов опухолей головного мозга. Механизм системы можно обобщить в следующей последовательности: во-первых, изображения МРТ импортируются из набора данных и подвергаются операциям предварительной обработки. Затем обработанные изображения преоб-

разуются в числовую форму путем извлечения дескрипторов признаков HOG. После этого классы меньшинства аугментируются в пространстве признаков с помощью алгоритма SMOTE для увеличения данных и балансировки их распределения. Размеры полученных признаков уменьшаются с помощью PCA, что повышает эффективность и предотвращает переобучение на этапе классификации. Наконец, на выходе системы разработанная многослойная нейронная сеть выполняет задачу определения типа аномалии головного мозга. Кроме того, в данной статье также изучается вариант использования других классификаторов машинного обучения и сравнивается их производительность с используемой нейронной сетью.

Набор данных и предобработка. В данной работе, как и во всех исследованиях, посвященных классификации основных типов опухолей головного мозга, используется стандартный набор данных Figshare [17]. Несбалансированный набор данных содержит в общей сложности 3064 изображения T1-CE МРТ опухолей головного мозга, распределенных по трем категориям, включая 708 менингиом, 1426 глиом и 930 опухолей гипофиза. Эти данные были собраны у 223 пациентов и для разных плоскостей: аксиальной, сагиттальной и коронарной. На рис. 2 показан образец набора данных.

Что касается предобработки, то любая операция, применяемая на этапе разработки, должна быть повторно выполнена для каждого входного изображения, когда предлагаемая модель будет введена в окончательное фактическое использование. Т. е., чем больше становится количество и сложность применяемых операций, тем больше времени требуется для вывода с использованием разработанной модели. В нашем подходе выполняется только минимальная предобработка, кото-



Рис. 1. Схема предлагаемой системы
Fig. 1. Flow diagram of the proposed system

рая включает нормализацию изображения и изменение размера с 512×512 до 224×224 , что снижает вычислительные затраты.

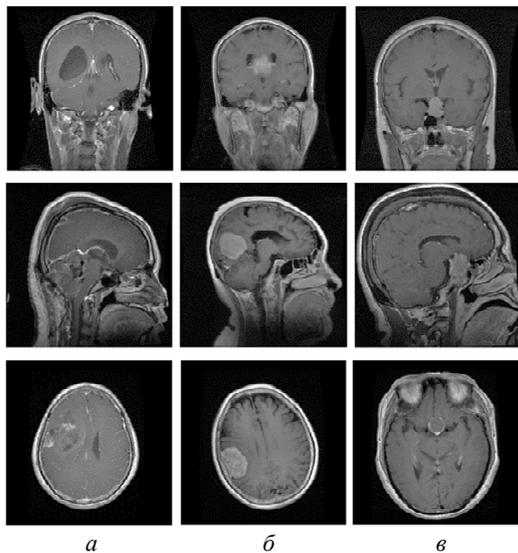


Рис. 2. Примеры из набора данных с разными видами: *a* – глиомы; *б* – менингиомы; *в* – опухоли гипофиза

Fig. 2. Examples from the dataset with different views: *a* – gliomas; *б* – meningiomas; *в* – pituitary tumors

Извлечение признаков. Блок-схема системы, представленная на рис. 1, показывает, что этап извлечения признаков из изображений МРТ мозга был выполнен в этом исследовании на основе метода гистограммы ориентированных градиентов. НОГ – это математическая процедура, которая преобразует изображения, предоставленные в качестве входных данных, в числовые признаки для использования в различных задачах – классификации и обнаружения объектов и т. п. Общий принцип основан на разделении изображения на пространственные элементы ячеек и получении вектора гистограммы для каждой ячейки с использованием направлений и значений ее градиентов. Векторы гистограмм группируются, образуя то, что известно как дескрипторы признаков НОГ [3], [18]. Несмотря на простоту, метод представления изображений с использованием гистограммы ориентированных градиентов оказался эффективным при решении многих задач компьютерного зрения и распознавания образов, включая обнаружение людей, животных и рукописных цифр [18]. В этом контексте использования, поскольку опухоль мозга может отображаться как контрастный элемент на изображении МРТ, признаки, полученные с помощью правильно настроенного метода НОГ, могут улавливать различные

характеристики каждого типа аномалии мозга. Механизм метода НОГ, использованного в данном исследовании, можно продемонстрировать в следующей последовательности:

1. Данное изображение делится на квадратные пространственные объекты фиксированного размера, называемые ячейками.

2. Направления и значения градиента для ячейки выводятся с использованием следующих формул:

$$g_x = C(x+1, y) - C(x-1, y);$$

$$g_y = C(x, y+1) - C(x, y-1);$$

$$g = \sqrt{g_x^2 + g_y^2};$$

$$\theta = \arctan \frac{g_y}{g_x},$$

где $C(x, y)$ – интенсивность пикселей ячейки; g_x – горизонтальные градиенты; g_y – вертикальные градиенты; g , θ – значения и направления градиентов.

3. Для каждой ячейки извлекается вектор гистограммы, состоящий из 9 ячеек, представляющих равное деление диапазона углов от 0 до 180° . В этом числовом векторе направления градиента отвечают за выбор блока гистограммы (histogram bin), в котором будет размещен взвешенный кумулятивный голос значений градиента.

4. С помощью скользящего окна ряд гистограмм ячеек группируется в блоки, посредством которых выполняется нормализация.

5. Наконец, все блоки объединяются для создания одного большого вектора, представляющего дескрипторы признаков НОГ целевого изображения.

Несколько параметров существенно влияют на производительность и сложность алгоритма НОГ и поэтому требуют экспертной настройки. Эти параметры, их роль и соответствующая настройка представлены следующим образом:

- Пикселей на ячейку: этот параметр относится к размеру ячейки в пикселях и контролирует количество и качество полученных признаков. На рис. 3 показано количество и представление признаков НОГ, полученных при использовании различных настроек размера ячейки. Выбор слишком маленького размера ячейки обеспечит огромное количество признаков, тем самым увеличивая вычислительные затраты. Кроме того, малый размер ячейки делает признаки более восприимчи-

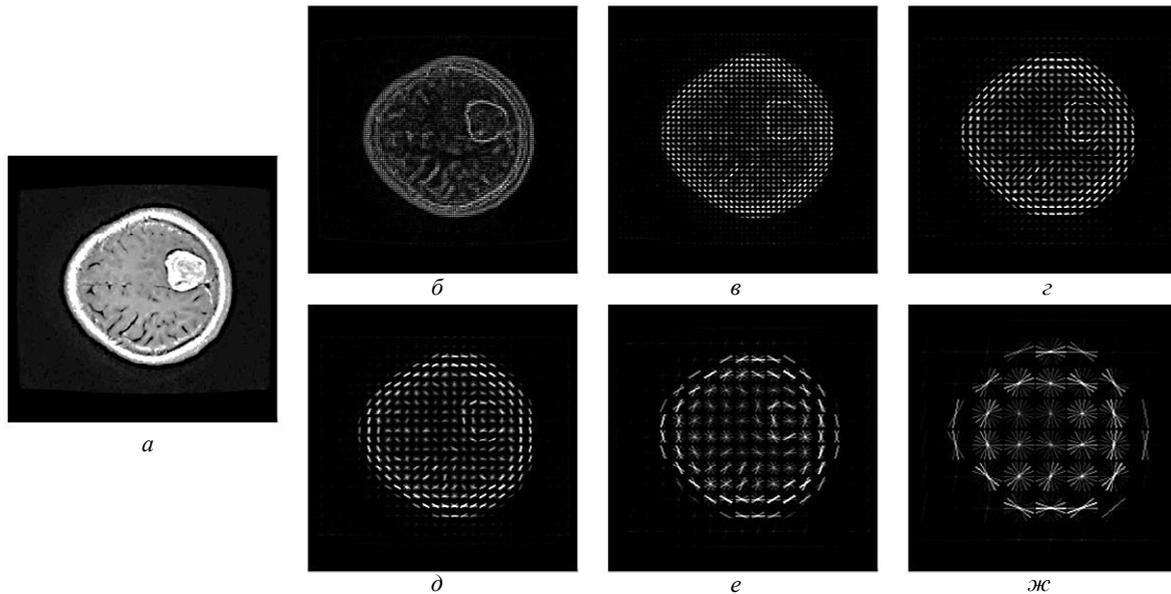


Рис. 3. Визуальная реконструкция признаков HOG для различных настроек параметра pixels_per_cell: *a* – исходное изображение; *б* – пикселей на ячейки = (2, 2), количество признаков = 112 896; *в* – пикселей на ячейки = (5, 5), количество признаков = 17 424; *г* – пикселей на ячейки = (7, 7), количество признаков = 9216; *д* – пикселей на ячейки = (9, 9), количество признаков = 5184; *е* – пикселей на ячейки = (15, 15), количество признаков = 1764; *ж* – пикселей на ячейки = (30, 30), количество признаков = 441

Fig. 3. Visual reconstruction of HOG features for different settings of pixels_per_cell parameter: *a* – source image; *б* – pixels per cell = (2, 2), number of features = 112 896; *в* – pixels per cell = (5, 5), number of features = 17 424; *г* – pixels per cell = (7, 7), number of features = 9216; *д* – pixels per cell = (9, 9), number of features = 5184; *е* – pixels per cell = (15, 15), number of features = 1764; *ж* – pixels per cell = (30, 30), number of features = 441

выми к шуму на изображениях. И наоборот, выбор слишком большого размера ячейки даст недостаточно информации, которая не сможет точно представить опухоль на изображениях МРТ. В данном исследовании был принят размер ячейки (9, 9). Этот параметр обеспечивает хорошее представление областей опухоли без преувеличения размера признаков.

- Ячеек на блок: количество ячеек в каждом блоке. Чтобы сделать полученные признаки независимыми от изменений освещенности, нормализация выполняется на векторах гистограмм. Этот процесс может быть более полезным, если нормализация выполняется для группы гистограмм, называемых блоком. Однако использование этой техники таким образом, что блок действует как скользящее окно, через которое перекрываются гистограммы, значительно увеличит количество признаков. Для достижения вычислительной эффективности мы используем размер блока (1,1), что означает, что каждый блок будет содержать только один вектор гистограммы без перекрытия.

- Метод нормализации: диапазон значений признаков HOG варьируется в зависимости от используемой нормализации, что, в свою очередь, может повлиять на общую производительность предлагаемой системы. Методы нормализации

могут включать L_1 -норму, L_2 -норму, L_1 -sqrt и L_2 -Hsu. В нашем исследовании использовалась нормализация L_2 -Hsu. Этот метод основан на применении L_2 -нормы к каждому вектору гистограммы с последующим отсечением для установки максимального значения на 0.2 и повторным применением нормализации. Формула для L_2 -нормы приведена ниже [3]:

$$L_2 - \text{norm} = \frac{\mathbf{u}}{\sqrt{\|\mathbf{u}\|_2^2 + \varepsilon^2}},$$

где \mathbf{u} – вектор гистограммы, а ε – малое постоянное число.

Применение метода HOG в соответствии с указанными настройками приведет к преобразованию набора данных изображения в табличный набор с 5184 столбцами, готовый к передаче на следующий этап представленного подхода.

Аугментация пространства признаков. Чтобы увеличить размер набора данных и сбалансировать его категории, изображения МРТ часто аугментируются посредством выполнения основных геометрических преобразований, которые включают обрезку, поворот, переворот, зеркальное отображение и многие другие [6], [8], [9], [13]–[15]. Однако не существует правила для соответствующего выбора или настройки этих пре-

образований, но это делается вручную и эвристически. Кроме того, все предыдущие преобразования происходят во входном пространстве, т. е. применяются к изображениям напрямую. Напротив, аугментация также может быть выполнена после извлечения признаков из входных изображений. Этот подход называется аугментацией пространства признаков. Обычно используемый метод аугментации выборок в пространстве признаков – это метод синтетической перевыборки меньшинства (SMOTE) [19].

Используя SMOTE, новая точка данных создается смещением случайной выборки, принадлежащей классу меньшинства, к одному из ее соседей, т. е. новая выборка лежит на плоскости, соединяющей две точки данных с одинаковой меткой класса [20]. На рис. 4 показано создание новых выборок с использованием SMOTE. Видно, что новые синтетические выборки отличаются от любой выборки в наборе данных, тем самым предоставляя модели новые знания. Следующая процедура демонстрирует, как работает алгоритм:

SMOTE procedure:

Define: T – number of samples in the minority class; x_i – the i^{th} sample of the minority class; x_{k_i} – the k^{th} neighbor of sample x_i ; N – number of synthetic samples to be added.

// Start

For each i in range from 1 to T , find the k -nearest neighbors of sample x_i .

Take a random sample x_i from the minority class.

Take a random neighbor x_{k_i} of sample x_i .

Create a new synthetic sample by applying the following formula:

$$x_{\text{new}} = x_i + \text{rand}(0,1) \times (x_{k_i} - x_i).$$

Go to 2 if the number of samples added is less than N .

// End

В этом исследовании только классы меньшинства, менингиомы и опухоли гипофиза, увеличены до того же размера, что и класс большинства – глиомы. Рис. 5 показывает распределение данных до и после аугментации. Использование этого подхода аугментации позволяет увеличить количество выборки без чрезмерного ущерба для распределения данных при достижении баланса классов.

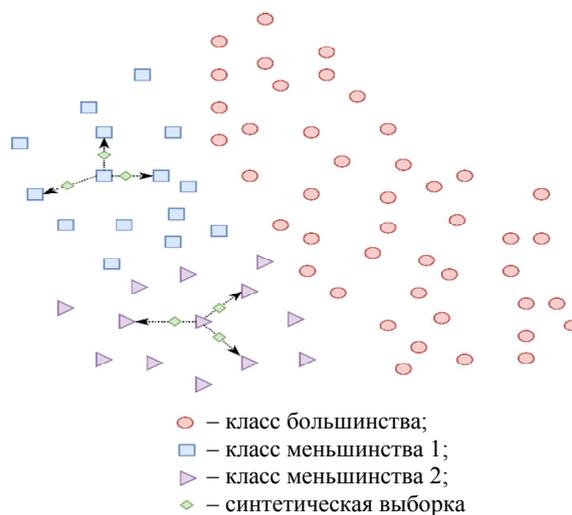


Рис. 4. Получение новых синтетических выборок с использованием SMOTE

Fig. 4. Acquisition of new synthetic samples using SMOTE

Классификация. Несколько представленных подходов использовали классификаторы нейронных сетей в качестве заключительной части глубокой модели CNN, выполняющей задачу обнаружения и классификации опухолей мозга. В этом исследовании предлагается специализированная искусственная нейронная сеть, которая принимает числовые признаки HOG в качестве входных данных и выдает тип аномалии мозга. Однако для ограничения размера параметров сети и устране-

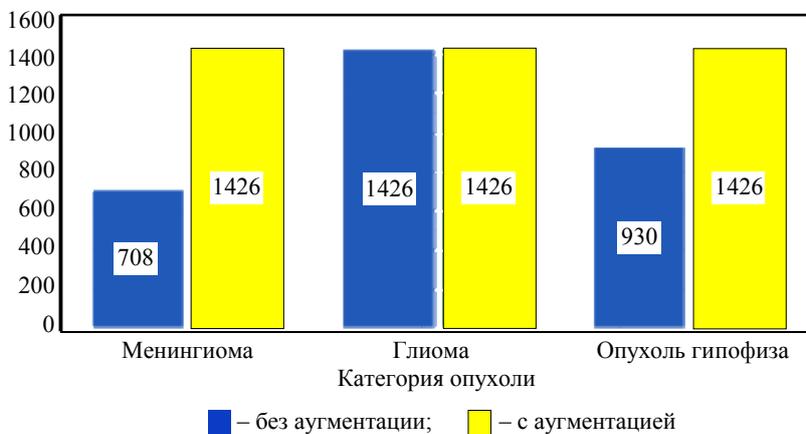


Рис. 5. Распределение данных до и после применения аугментации

Fig. 5. Data distribution before and after applying augmentation

ния избыточной информации в признаках HOG и, таким образом, снижения общей вычислительной стоимости применяется анализ главных компонент (PCA), чтобы иметь только 100 признаков в качестве входных данных нейронной модели.

Для разработки нейронной сети используется плотная последовательная модель. Эта линейная топология основана на последовательном размещении набора нейронных слоев, где каждый нейрон глубоко связан со всеми узлами предыдущего слоя. Топология сети в основном состоит из шести обучаемых слоев с тремя другими, которые не требуют подгонки параметров. За входным слоем следуют пять скрытых, которые используют ReLU (Rectified linear unit) в качестве активации, а затем выходной слой с функцией SoftMax, которая дает окончательное решение о классификации. Стратегия регуляризации, используемая для предотвращения переобучения в сети, включала добавление двух слоев исключения (Dropout). Этот наивный подход к регуляризации случайным образом отбрасывает определенное количество нейронов (в процентах) в слое на этапе обучения и сохраняет их веса необновленными, тем самым не давая сети запомнить входные данные. В табл. 1 и 2 показаны детали спроектированной архитектуры нейронной сети и настройки ее гиперпараметров соответственно. Можно заметить, что количество параметров

предлагаемой модели намного меньше, чем у любой модели CNN, которая обычно имеет несколько миллионов параметров, требуя больших вычислительных ресурсов и более длительного времени обучения и вывода.

Эксперименты, результаты и обсуждение.

В этом исследовании все эксперименты проводятся с использованием кодов Python, написанных и выполненных в среде Jupyter Notebook, размещенной в облачном вычислительном сервисе Google Colab CPU. Эксперименты в основном включают оценку разработанной системы без аугментации и с ней в пространстве признаков, т. е. исследование возможности использования аугментации для улучшения общей производительности модели. Кроме того, заменяется предложенный нейронный классификатор и тестируются другие классические классификаторы машинного обучения. Стоит отметить, что использовался общепринятый коэффициент разделения данных в области медицинской визуализации. После применения перетасовки данных 80 % выборок выделяются для обучения и 20 % для проверки.

На рис. 6 и 7 показаны кривые точности и потерь предлагаемой модели без и с аугментацией соответственно. Используемый решатель успешно оптимизирует веса нейронной сети в обоих сценариях, что отражается в увеличении точно-

Табл. 1. Предлагаемая архитектура нейронной сети
Tab. 1. Proposed neural network architecture

Название слоя (тип)	Характеристика	Функция активации	Количество параметров
Input_1 (Input)	100 numerical inputs	–	0
Drop_2 (Dropout)	20 % dropout	–	0
Dense_3 (Dense)	100 neurons	ReLU	10 100
Drop_4 (Dropout)	20 % dropout	–	0
Dense_5 (Dense)	100 neurons	ReLU	10 100
Dense_6 (Dense)	64 neurons	ReLU	6464
Dense_7 (Dense)	32 neurons	ReLU	2080
Dense_8 (Dense)	10 neurons	ReLU	330
Output_9 (Dense)	3 neurons	SoftMax	33

Табл. 2. Настройка параметров нейронной сети
Tab. 2. Setting neural network parameters

Параметр сети	Параметры настройки
Оптимизатор	Adam
Темп обучения	0.001
Функция потерь	Categorical cross entropy
Эпохи	70
Перемешивание	True
Размер партии	16

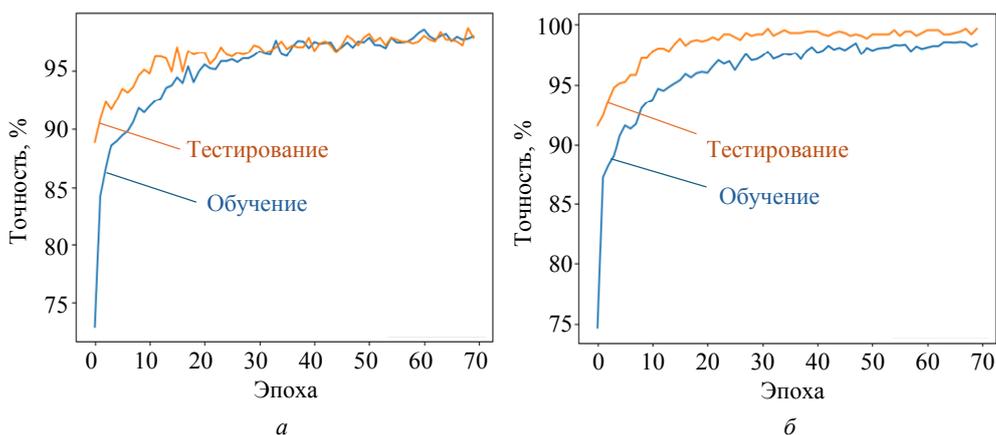


Рис. 6. Кривые точности предлагаемой системы: *a* – без аугментации; *б* – с аугментацией
 Fig. 6. Accuracy curves of the proposed system: *a* – without augmentation; *б* – with augmentation

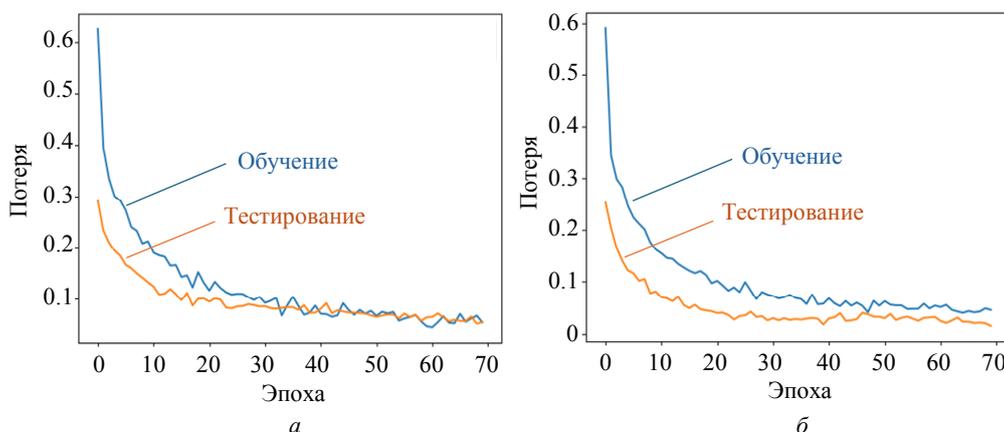


Рис. 7. Кривые потерь предлагаемой системы: *a* – без аугментации; *б* – с аугментацией
 Fig. 7. Loss curves of the proposed system: *a* – without augmentation; *б* – with augmentation

сти и уменьшении потерь по мере прохождения итераций обучения. Четко прослеживается эффект добавленных слоев исключения (Dropout) в предотвращении переобучения. Использование аугментации привело к получению более стабильных кривых, которые устойчивы к переобучению, и более быстрого достижения максимального значения точности, близкого к идеальной точке, после меньшего количества итераций.

Производительность разработанной модели выражена через оценочные метрики, представленные в табл. 3. В обоих случаях тестирования модели с аугментацией и без нее были достигнуты высокие значения для всех рассчитанных метрик. Добавление фазы аугментации в системный поток улучшило точность с 97.88 до 99.65 % и оценку F1 с 97.67 до 99.64 %, в то время как полнота и точность (precision) увеличились с 97.80 до 99.68 и с 97.55 до 99.60 % соответственно. Матрицы ошибок, приведенные на рис. 8, показывают, что из всего тестового набора данных только 13 выборок (рис. 8, *a*) были неправильно классифицированы с частотой ошибок не более 2.12 %.

Однако при использовании аугментации частота ошибок классификации значительно снижается (до 0.35 %), и только 3 выборки (рис. 8, *б*) были неправильно идентифицированы.

Табл. 3. Отчет о классификации предлагаемой системы
 Tab. 3. Classification report of the proposed system

Подход	Метрика оценки, %			
	Точность (precision)	Полнота	F1-оценка	Точность (accuracy)
Без аугментации	97.55	97.80	97.67	97.88
С аугментацией	99.60	99.68	99.64	99.65

Заключительный этап классификации аномалий мозга выполняется предлагаемой нейронной сетью. Эффективность представленной сети проверяется сравнением ее производительности с набором известных классификаторов машинного обучения, а именно: машина опорных векторов (SVM), логистическая регрессия (LR), дерево решений (DT) и случайный лес (RF). Параметры алгоритмов задаются в соответствии с табл. 4 с учетом того, что все этапы системы, включая

предобработку, извлечение признаков, аугментацию пространства признаков и оптимизацию признаков, остаются постоянными. Значения метрик производительности протестированных алгоритмов, а также нейронного классификатора показаны на рис. 9. Среди альтернативных моделей дерево решений дает самую низкую производительность с точностью 91.94 %, в то время как случайный лес достигает самой высокой производительности с точностью 96.73 %, что на 2.92 % меньше точности нейронного классификатора. Для SVM и LR получена точность 94.86 и 93.34 % соответственно. Табл. 5 показывает производительность различных методов классификации при распознавании каждой категории опухолей по отдельности. Можно заметить, что разработанная

нейронная сеть достигает высоких показателей для всех классов опухолей мозга, в то время как остальные классификаторы смещены в сторону одного из типов в разной степени.

Табл. 4. Альтернативные модели классификации и их параметры
Tab. 4. Alternative classification models and their parameters

Классификатор	Параметр	Настройка
SVM	Ядро	Linear
	Фактор регуляризации C	1
LR	Мах итерация	1000
	Фактор регуляризации C	1
DT	Мах глубина	50
	Критерий	Entropy
RF	Мах глубина	50
	Количество оценщиков	100
	Критерий	Entropy

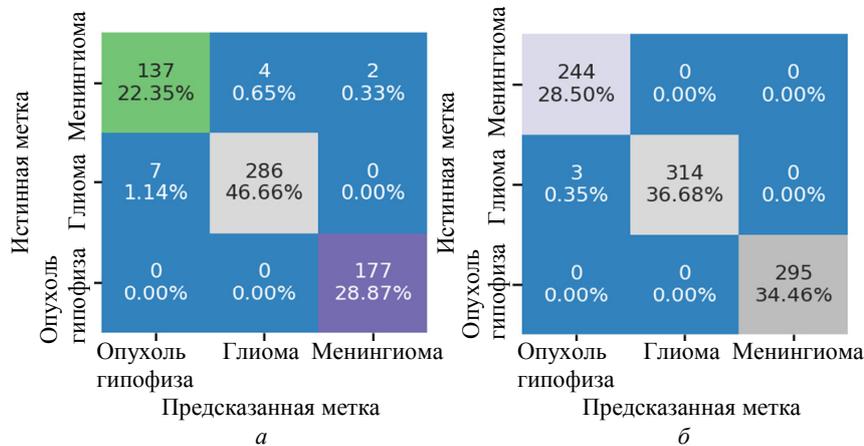


Рис. 8. Матрицы ошибок предлагаемой системы:
а – без аугментации; б – с аугментацией
Fig. 8. Confusion matrices of the proposed system:
а – without augmentation; б – with augmentation

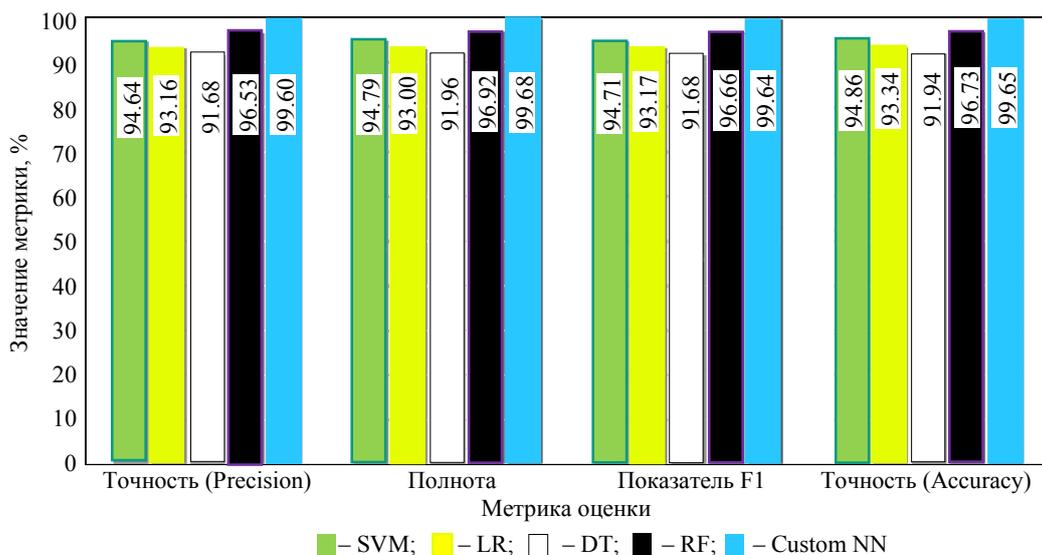


Рис. 9. Сравнение производительности предлагаемой нейронной сети с другими классификаторами машинного обучения
Fig. 9. Performance comparison of the proposed neural network with several machine learning classifiers

Табл. 5. Производительность предложенной системы для каждого класса опухолей отдельно при использовании разных классификаторов

Tab. 5. Performance of the proposed system for each tumor class separately when using different classifiers

Алгоритм	Тип опухоли	Метрика оценки, %		
		Точность (Precision)	Полнота	F1-оценка
SVM	Менингиома	91.16	93.03	92.09
	Глиома	95.79	93.38	94.57
	Опухоль гипофиза	96.98	97.97	97.47
LR	Менингиома	90.53	90.16	90.35
	Глиома	93.27	91.80	92.53
	Опухоль гипофиза	95.68	97.63	96.64
DT	Менингиома	91.63	98.77	95.07
	Глиома	99.33	93.69	96.43
	Опухоль гипофиза	98.64	98.31	98.47
RF	Менингиома	87.65	87.30	87.47
	Глиома	91.75	91.17	91.46
	Опухоль гипофиза	95.64	96.61	96.12
Custom NN	Менингиома	98.79	100	99.39
	Глиома	100	99.05	99.52
	Опухоль гипофиза	100	100	100

Табл. 6. Сравнение производительности предлагаемой системы и моделей, представленных в последних работах

Tab. 6. Performance comparison between the proposed system and models presented in recent works

Источник, год	Подход	Метрика оценки, %	
		Точность (Accuracy)	F1-оценка
[6], 2022	Three-layer CNN	93.10	–
[6], 2022	GLCM+RF	75.20	–
[6], 2022	GLDM+RF	77.64	–
[6], 2022	LBF+SVM	84.95	–
[6], 2022	HARALICK+SVM	76.01	–
[7], 2023	Custom CNN	96	95.33
[8], 2023	Custom CNN+SVM	96	96.92
[9], 2024	DenseNet169+Majority vote (XGBoost+SVM+RF)	95.10	94
[10], 2023	Three parallel CNNs+Majority vote (KNN classifiers)	95.6	95.07
[10], 2023	Feature fusion of three parallel CNNs+SVM	95.4	94.93
[13], 2023	Feature fusion of two parallel CNNs	97.60	97.60
[14], 2023	YOLOv8	–	92.47
[15], 2023	NADA + VGG16	96.01	95.68
[16], 2024	VGG19+L1-LR feature selection+SVM	98.53	98.34
Our	HOG+SMOTE+PCA+DNN	99.65	99.64

Табл. 6 показывает сравнение производительности предлагаемой модели и недавних работ, оцененных на том же наборе данных. Исследователи предложили различные подходы к извлечению признаков из изображений МРТ мозга, включая созданные вручную экстракторы признаков [6], специализированные сверточные сети

[6]–[8], [10], предварительно обученные или повторно обученные глубокие эталонные модели [9], [10], [14]–[16] и методы слияния признаков [10], [13]. Для этапа классификации признаков предложенные варианты были ограничены использованием полностью связанных нейронных сетей [6]–[8], [13]–[15], классических алгоритмов

машинного обучения [6], [8], [10], [16] и ансамблевого голосования нескольких классификаторов [9], [10]. Среди этих работ модель в [16] достигла наивысшей точности 98.53 %. Как заявили исследователи, это связано с используемым элементом оптимизации признаков, которым обычно пренебрегают во многих моделях. В нашем подходе, учитывая низкую сложность с точки зрения размера обучаемых параметров и простоту метода извлечения признаков, были получены превосходные результаты с точностью, которая превзошла самые современные системы, представленные в литературе.

Заключение. В этой статье представлен подход машинного обучения для повышения эффективности автоматизированной дифференциации опухолей головного мозга на изображениях МРТ. Предлагаемая система состоит из четырех основных этапов, включая предварительную обработку, извлечение, оптимизацию признаков и классификацию. Минимальная предобработка выполняется посредством нормализации и изменения размера исходных изображений МРТ, взятых из целевого набора данных. Числовые признаки извлекаются из обработанных изображений МРТ с использованием экспертно настроенного алгоритма гистограммы ориентированных градиентов. Этап оптимизации признаков включает использование анализа главных компонент для уменьшения размеров полученных признаков до определенного размера. Наконец, признаки передаются для обучения многослойного нейронного классификатора, созданного с нуля, для определения типа опухоли головного мозга, выраженного на изображении МРТ. Кроме того, предлагаемая модель улучшается путем добавления этапа аугментации, применяемого к классам меньшинства в пространстве признаков.

Производительность предлагаемой модели оценивалась с использованием различных метрик, включая точность, оценку F1, точность (precision) и полноту (recall), кривые потерь и точности, а также матрицы ошибок. Несмотря на про-

стоту конструкции, представленная модель достигла высокой производительности в обоих вариантах использования с аугментацией и без нее, превзойдя многие современные подходы. Добавление этапа аугментации в пространство признаков привело к повышению точности и улучшению способности избегать переобучения. Разработанная нейронная сеть также показала явное превосходство над классическими алгоритмами машинного обучения при выполнении окончательной задачи классификации.

Основная цель предлагаемого подхода заключается не в полной замене врачей-рентгенологов, а в предоставлении быстрого и высокоточного метода диагностики, который поддерживает принятие экспертных решений и снижает необходимость обширных консультаций по медицинским случаям. Это преимущество имеет первостепенное значение, когда специалисты недостаточно доступны, особенно в чрезвычайных обстоятельствах в эпидемиях, кризисах и конфликтах.

Как и в литературе, в этом исследовании рассматривается классификация трех типов опухолей головного мозга: глиома, менингиома и опухоль гипофиза. Хотя эти категории вместе составляют около 75 % всех опухолей головного мозга, все еще существует необходимость охватить любые другие категории, чтобы получить всеобъемлющую диагностическую систему. Кроме того, разработанные модели не подвергаются никаким практическим испытаниям в учреждениях или медицинских центрах, что снижает вероятность их принятия медицинским сообществом. Эти недостатки помогают в составлении планов будущего развития, которые включают стремление расширить систему для обеспечения возможности обнаружения более широкого спектра опухолей головного мозга, затем проведение нескольких этапов клинических испытаний под наблюдением экспертов перед представлением окончательной системы в качестве готового к использованию продукта.

Список литературы

1. Barkade G., Bhosale P., Shirsath S. Overview of brain cancer, its symptoms, diagnosis and treatment // IP Intern. J. of Comprehensive and Advanced Pharmacol. 2023. Vol. 8, no. 3. P. 159-164. doi: 10.18231/j.ijcaap.2023.027.
2. Deep transfer learning approaches in performance analysis of brain tumor classification using MRI images / C. Srinivas, N. K. S., M. Zakariah, Y. Alothaibi,

K. Shaukat, B. Partibane, H. Awal // J. of Healthcare Engin. 2022. Vol. 2022. P. 1-17. doi: 10.1155/2022/3264367.
3. Alavi S. E., Zare E., Rashti M. j. Brain tumors detection on MRI images through extracting HOG features // JOAASR. 2018. Vol. 2, no. 1. P. 9-25. doi: 10.46947/joaasr21201896.
4. From first symptoms to diagnosis: Initial clinical presentation of primary brain tumors / B. Alther, V. My-

lius, M. Weller, AR. Gantenbein // *Clinical & Translational Neurosci.* 2020. Vol. 4, no. 2. P. 1–7. doi: 10.1177/2514183X20968368.

5. Perkins A., Liu G. Primary brain tumors in adults: diagnosis and treatment // *Am. Fam. Phys.* 2016. Vol. 93, no. 3. P. 211–217.

6. Sowrirajan S. R., Balasubramanian S. Brain tumor classification using machine learning and deep learning algorithms // *IJEER.* 2022. Vol. 10, no. 4. P. 999–1004. doi: 10.37391/IJEER.100441

7. Jaspin K., Selvan S. Multiclass convolutional neural network based classification for the diagnosis of brain MRI images // *Biomed. Signal Proc. and Control.* 2023. Vol. 82, no. 6. P. 104542. doi: 10.1016/j.bspc.2022.104542.

8. Biswas A., Islam M. S. A hybrid deep CNN-SVM approach for brain tumor classification // *JISEBI.* 2023. Vol. 9, no. 1. P. 1–15. doi: 10.20473/jisebi.9.1.1-15.

9. Hybrid-NET: A fusion of DenseNet169 and advanced machine learning classifiers for enhanced brain tumor diagnosis / S. U. R. Khan, M. Zhao, S. Asif, X. Chen // *IMA.* 2024. Vol. 34, no. 1. doi: 10.1002/ima.22975.

10. Deepak S., Ameer P. M. Brain tumor categorization from imbalanced MRI dataset using weighted loss and deep feature fusion // *Neurocomputing.* 2023. Vol. 520. P. 94–102. doi: 10.1016/j.neucom.2022.11.039.

11. Accurate anomaly detection in medical images using transfer learning and data optimization: MRI and CT as case studies / Y. Nizamli, A. Filatov, W. Fadel, Y. Shichkina // *V Intern. Conf. on Neural Networks and Neurotechnol. (NeuroNT).* Saint Petersburg, RF: IEEE, 2024. P. 170–173. doi: 10.1109/NeuroNT62606.2024.10585603.

12. Early tumor diagnosis in brain MR images via deep convolutional neural network model / T. Das, P. Roy, M. Uddin, K. Srinivasan, C.-Y. Chang, S. Syed-Abdul // *Computers, Materials & Continua.* 2021. Vol. 68, no. 2. P. 2413–2429. doi: 10.32604/cmcc.2021.016698.

13. Rahman T., Islam M. S. MRI brain tumor detection and classification using parallel deep convolutional neural networks // *Measurement: Sensors.* 2023. Vol. 26, no. 1. P. 100694. doi: 10.1016/j.measen.2023.100694.

14. Passa R. S., Nurmaini S., Rini D. P. YOLOv8 based on data augmentation for MRI brain tumor detection // *Scientific J. of Informatics.* 2023. Vol. 10, no. 3. P. 363–370. doi: 110.15294/sji.v10i3.45361.

15. Sowrirajan S. R., Balasubramanian S., Raj R. S. P. MRI brain tumor classification using a hybrid VGG16-NADE model // *Brazilian Archives of Biol. and Technol.* 2023. Vol. 66. P. 1–18. doi: 10.1590/1678-4324-2023-220071.

16. Nizamli Ya. A., Filatov A. Yu. Improving transfer learning performance for abnormality detection in brain MRI images using feature optimization techniques // *2024 XXVII Intern. Conf. on Soft Computing and Measurements (SCM).* Saint Petersburg, RF: IEEE, 2024. P. 432–435. doi: 10.1109/SCM62608.2024.10554161.

17. Brain tumor dataset. URL: https://figshare.com/articles/dataset/brain_tumor_dataset/1512427/5 (дата обращения: 26.03.2024).

18. Moniruzzaman M. D., Shamsul Islam S. M. Evaluation of different features and machine learning classifiers for classification of rays from underwater digital images // *2018 Intern. Conf. on Machine Learning and Data Engin. (ICMLDE).* Sydney, NSW, Australia: IEEE, 2018. P. 83–90. doi: 10.1109/ICMLDE.2018.00025.

19. Shorten C., Khoshgoftaar T. A survey on image data augmentation for deep learning // *J. of Big Data.* 2019. Vol. 6, no. 1. doi: 10.1186/s40537-019-0197-0.

20. Smote: Synthetic minority over-sampling technique / N. Chawla, K. Bowyer, L. Hall, W. Kegelmeyer // *J. of Artificial Intelligence Research.* 2002. Vol. 16. P. 321–357. doi: 10.1613/jair.953.

Информация об авторах

Низамли Яссер Ахмад – аспирант кафедры математического обеспечения и применения ЭВМ СПбГЭТУ «ЛЭТИ».

E-mail: yanizamli@stud.etu.ru

<https://orcid.org/0009-0003-0129-6368>

Филатов Антон Юрьевич – канд. техн. наук, доцент кафедры математического обеспечения и применения ЭВМ СПбГЭТУ «ЛЭТИ».

E-mail: aifilatov@etu.ru

<https://orcid.org/0000-0003-4298-8523>

References

1. Barkade G., Bhosale P., Shirsath S. Overview of brain cancer, its symptoms, diagnosis and treatment // *IP Intern. J. of Comprehensive and Advanced Pharmacol.* 2023. Vol. 8, no. 3. P. 159–164. doi: 10.18231/j.ijcaap.2023.027.

2. Deep transfer learning approaches in performance analysis of brain tumor classification using MRI images / C. Srinivas, N. K. S., M. Zakariah, Y. Alothaibi,

K. Shaukat, B. Partibane, H. Awal // *J. of Healthcare Engin.* 2022. Vol. 2022. P. 1–17. doi: 10.1155/2022/3264367.

3. Alavi S. E., Zare E., Rashti M. j. Brain tumors detection on MRI images through extracting HOG features // *JOAASR.* 2018. Vol. 2, no. 1. P. 9–25. doi: 10.46947/joaasr21201896.

4. From first symptoms to diagnosis: Initial clinical presentation of primary brain tumors / B. Alther, V. My-

lius, M. Weller, AR. Gantenbein // *Clinical & Translational Neurosci.* 2020. Vol. 4, no. 2. P. 1–7. doi: 10.1177/2514183X20968368.

5. Perkins A., Liu G. Primary brain tumors in adults: diagnosis and treatment // *Am. Fam. Phys.* 2016. Vol. 93, no. 3. P. 211–217.

6. Sowrirajan S. R., Balasubramanian S. Brain tumor classification using machine learning and deep learning algorithms // *IJEER.* 2022. Vol. 10, no. 4. P. 999–1004. doi: 10.37391/IJEER.100441

7. Jaspin K., Selvan S. Multiclass convolutional neural network based classification for the diagnosis of brain MRI images // *Biomed. Signal Proc. and Control.* 2023. Vol. 82, no. 6. P. 104542. doi: 10.1016/j.bspc.2022.104542.

8. Biswas A., Islam M. S. A hybrid deep CNN-SVM approach for brain tumor classification // *JISEBI.* 2023. Vol. 9, no. 1. P. 1–15. doi: 10.20473/jisebi.9.1.1-15.

9. Hybrid-NET: A fusion of DenseNet169 and advanced machine learning classifiers for enhanced brain tumor diagnosis / S. U. R. Khan, M. Zhao, S. Asif, X. Chen // *IMA.* 2024. Vol. 34, no. 1. doi: 10.1002/ima.22975.

10. Deepak S., Ameer P. M. Brain tumor categorization from imbalanced MRI dataset using weighted loss and deep feature fusion // *Neurocomputing.* 2023. Vol. 520. P. 94–102. doi: 10.1016/j.neucom.2022.11.039.

11. Accurate anomaly detection in medical images using transfer learning and data optimization: MRI and CT as case studies / Y. Nizamli, A. Filatov, W. Fadel, Y. Shichkina // *V Intern. Conf. on Neural Networks and Neurotechnol. (NeuroNT).* Saint Petersburg, RF: IEEE, 2024. P. 170–173. doi: 10.1109/NeuroNT62606.2024.10585603.

12. Early tumor diagnosis in brain MR images via deep convolutional neural network model / T. Das, P. Roy, M. Uddin, K. Srinivasan, C.-Y. Chang, S. Syed-Abdul // *Computers, Materials & Continua.* 2021. Vol. 68, no. 2. P. 2413–2429. doi: 10.32604/cmc.2021.016698.

13. Rahman T., Islam M. S. MRI brain tumor detection and classification using parallel deep convolutional neural networks // *Measurement: Sensors.* 2023. Vol. 26, no. 1. P. 100694. doi: 10.1016/j.measen.2023.100694.

14. Passa R. S., Nurmaini S., Rini D. P. YOLOv8 based on data augmentation for MRI brain tumor detection // *Scientific J. of Informatics.* 2023. Vol. 10, no. 3. P. 363–370. doi: 110.15294/sji.v10i3.45361.

15. Sowrirajan S. R., Balasubramanian S., Raj R. S. P. MRI brain tumor classification using a hybrid VGG16-NADE model // *Brazilian Archives of Biol. and Technol.* 2023. Vol. 66. P. 1–18. doi: 10.1590/1678-4324-2023.220071.

16. Nizamli Ya. A., Filatov A. Yu. Improving transfer learning performance for abnormality detection in brain MRI images using feature optimization techniques // *2024 XXVII Intern. Conf. on Soft Computing and Measurements (SCM).* Saint Petersburg, RF: IEEE, 2024. P. 432–435. doi: 10.1109/SCM62608.2024.10554161.

17. Brain tumor dataset. URL: https://figshare.com/articles/dataset/brain_tumor_dataset/1512427/5 (data obrasheniya: 26.03.2024).

18. Moniruzzaman M. D., Shamsul Islam S. M. Evaluation of different features and machine learning classifiers for classification of rays from underwater digital images // *2018 Intern. Conf. on Machine Learning and Data Engin. (iCMLDE).* Sydney, NSW, Australia: IEEE, 2018. P. 83–90. doi: 10.1109/iCMLDE.2018.00025.

19. Shorten C., Khoshgoftaar T. A survey on image data augmentation for deep learning // *J. of Big Data.* 2019. Vol. 6, no. 1. doi: 10.1186/s40537-019-0197-0.

20. Smote: Synthetic minority over-sampling technique / N. Chawla, K. Bowyer, L. Hall, W. Kegelmeyer // *J. of Artificial Intelligence Research.* 2002. Vol. 16. P. 321–357. doi: 10.1613/jair.953.

Information about the authors

Yasser A. Nizamli – postgraduate student of the Department of Mathematical Support and Computer Applications, Saint Petersburg Electrotechnical University.

E-mail: yanizamli@stud.etu.ru

<https://orcid.org/0009-0003-0129-6368>

Anton Yu. Filatov – Cand. Sci. (Eng.), Associate Professor of the Department of Mathematical Support and Computer Applications, Saint Petersburg Electrotechnical University.

E-mail: aifilatov@etu.ru

<https://orcid.org/0000-0003-4298-8523>

Статья поступила в редакцию 03.10.2024; принята к публикации после рецензирования 17.12.2024; опубликована онлайн 28.02.2025.

Submitted 03.10.2024; accepted 17.12.2024; published online 28.02.2025.
