

# Повышение эффективности трансферного обучения для обнаружения аномалий на изображениях МРТ головного мозга с использованием методов оптимизации признаков

Я. А. Низамли<sup>1</sup>, А. Ю. Филатов<sup>2</sup>

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

<sup>1</sup>yanizamli@stud.etu.ru, <sup>2</sup>aifilatov@etu.ru

**Аннотация.** Точная и ранняя диагностика опухолей головного мозга играет жизненно важную роль в определении соответствующего лечения и повышении показателей выживаемости. Ручная диагностика с использованием изображений МРТ часто подвержена ошибкам и может быть утомительной и трудоемкой процедурой. В результате широко используются автоматизированные компьютерные системы, использующие методы искусственного интеллекта и машинного обучения. Однако точная диагностика типа опухоли головного мозга остается серьезной и сложной задачей для современного исследовательского сообщества в области медицинской визуализации. В этой статье мы представляем усовершенствованный подход к трансферному обучению, целью которого является дифференциация типов опухолей головного мозга с использованием изображений МРТ с достижением самых современных показателей. В предлагаемом подходе предварительно обученная сеть VGG-19 с фиксированными весами используется для преобразования изображений МРТ в числовое представление высокого уровня. Извлеченные признаки затем передаются в алгоритм машины опорных векторов для классификации опухолей головного мозга в одну из трех основных категорий: глиома, менингиома и гипофиз. Для дальнейшего улучшения производительности модели была исследована эффективность использования методов оптимизации признаков, основанных на функции сходства радиального базиса и L1-логистической регрессии. Для оценки использовался эталонный набор данных Figshare, содержащий 3064 изображения МРТ, после серии операций обработки. Предложенная система достигла высокой общей точности 98,53 %, превзойдя другие аналоги.

**Ключевые слова:** МРТ, опухоли головного мозга, трансферное обучение, оптимизация признаков

## I. ВВЕДЕНИЕ

Опухоль головного мозга определяется как развитие аномальных клеток в ткани головного мозга и окружающих областях. Доброкачественная опухоль головного мозга растет медленно и не считается раковой. Напротив, в случае злокачественной опухоли головного мозга раковые клетки бурно распространяются и проникают в окружающие ткани, нанося значительный

ущерб функциям нервной системы [1]. В зависимости от места происхождения большинство опухолей головного мозга могут относиться к одному из трех типов: глиоме, менингиоме и опухоли гипофиза. Глиомы возникают в долях головного или спинного мозга, тогда как менингиомы развиваются в мозговых оболочках – защитных тканях, окружающих головной и спинной мозг. С другой стороны, аденомы гипофиза возникают в гипофизе, расположенном за носом. Эти три типа составляют примерно 75 % всех опухолей головного мозга [2, 3]. Сообщалось, что головные боли, эпилептические припадки, когнитивные и сенсорные расстройства, проблемы со зрением, рвота и тошнота являются частыми симптомами. Процедуры ведения и лечения различаются в зависимости от ряда факторов, включая тип и стадию опухоли, и многих других. Магнитно-резонансная томография считается основным методом диагностики опухолей головного мозга благодаря своей точности и способности давать более детальные изображения органов и мягких тканей [4]. Однако, ручная диагностика подвержена ошибкам и отнимает много драгоценного времени, особенно в свете растущей нагрузки на системы здравоохранения. Поэтому специалисты прибегают к компьютерным системам, поддерживаемым глубоким обучением, которые во многих случаях доказали свою способность превосходить людей.

В последние годы исследовательское сообщество внедрило множество методов глубокого обучения с целью улучшения эффективности классификации ранее упомянутых опухолей головного мозга. Исследователи в [2] предложили модель CNN для классификации аномалий на изображениях МРТ головного мозга. Модель состоит из трех слоев свертка-пулинга, за которыми следует четырехслойная полносвязная нейронная сеть. Авторы заявили, что разработанная модель достигла точности 96 % на наборе данных МРТ Figshare. В [3] предварительно обученная модель DensNet169 использовалась для извлечения признаков из изображений МРТ головного мозга и последующей передачи этих признаков трем классификаторам (RF, SVM и XGBoost), которые выполняют голосование

большинством для принятия окончательного решения. Предложенная архитектура достигла точности 95,10 %. Авторы в [5] представили специальную сеть CNN, состоящую из пяти сверточных слоев с четырьмя слоями пулинга, за которыми следует двухслойный нейронный классификатор. Предлагаемая сеть обучается, а затем используется в качестве экстрактора признаков, которые будут переданы в классификатор SVM. Сообщается, что точность составляет 96 %. В аналогичном исследовании [6] три сверточные нейронные сети, структурно идентичные, но различающиеся по функциям потерь, обучаются, а затем используются в качестве экстракторов признаков. Каждая модель состоит из пяти сверточных слоев с четырьмя слоями пулинга, за которыми следует двухслойный нейронный классификатор. Извлеченные признаки передаются трем экземплярам одного и того же классификатора, чтобы сделать окончательный прогноз на основе большинства голосов. Предложенная модель достигла наивысшей точности 95,6 % при использовании KNN в качестве классификатора. Исследователи в [7] использовали нейронную авторегрессионную систему оценки распределения для сглаживания краев опухоли и удаления избыточности на изображениях МРТ. Обработанные выходные данные передаются в предварительно обученную модель VGG-16 для извлечения числовых признаков, которые затем будут использоваться для обучения трехслойного полносвязного классификатора нейронной сети. По оценкам авторов, разработанная модель достигла точности 96,01 %. В [8] архитектура YOLO применялась для задачи классификации опухолей головного мозга. Исследователи использовали последнюю версию модели, получившую название YOLOv8. Предложенная модель достигла точности (precision) 94,2 % и полноты (recall) 90,8 %. Показатель F1 можно извлечь как среднее гармоническое между точностью и полнотой, таким образом достигнув значения 92,47 %. Исследователи в [9] разработали систему глубокого обучения, основанную на двух CNN, работающих параллельно. Обе сети имеют одинаковую архитектуру из трех последовательных слоев свертка-пулинга, отличаясь только размером сверточного окна. Выходные данные двух сетей объединяются, а затем передаются в двухслойную полностью связанную нейронную сеть. Для набора данных Figshare авторы сообщили о точности 97,60 % при выделении 10 % данных для тестирования и точности всего 96,16 % при использовании 20 % для тестирования.

Все предыдущие работы с трудом достигают необходимой высокой точности классификации, особенно учитывая важнейшую задачу сохранения человеческой жизни. Кроме того, обучение глубоких сетей с огромным количеством параметров с нуля на относительно небольшом наборе данных может привести к переобучению разработанной модели, что вызовет неточное обобщение на новые реальные данные. В нашей работе мы стремимся решить рассматриваемые проблемы, и поэтому наибольший вклад этого исследования резюмируется следующим образом: (1) предложить подход, направленный на классификацию опухолей головного мозга на изображениях МРТ на основе числовых признаков высокого уровня,

извлеченных из глубокой предварительно обученной модели, (2) улучшить производительность модели трансферного обучения, используя методы оптимизации признаков с учителем и без учителя, (3) оценить производительность предлагаемой модели с использованием различных показателей производительности, (4) провести сравнение предлагаемой системы и моделей, представленных в литературе.

## II. МАТЕРИАЛЫ И МЕТОДЫ

На рис.1 показана архитектура окончательного предложенного подхода, где последовательность операций системы можно резюмировать следующим образом: (1) изображения МРТ головного мозга подвергаются ряду операций обработки и улучшения, (2) обработанные изображения передаются в предварительно обученную модель VGG-19 с удаленным классификационным слоем для извлечения числовых признаков, (3) признаки, извлеченные из каждого изображения, преобразуются в одномерный массив с использованием выравнивающего слоя (flatten layer), (4) пространство признаков высокой размерности оптимизируется путем корректировки штрафного члена L1 в функции оптимизации алгоритма логистической регрессии, (5) классификатор SVM с функцией ядра RBF используется для классификации признаков по одному из трех типов опухоли головного мозга.

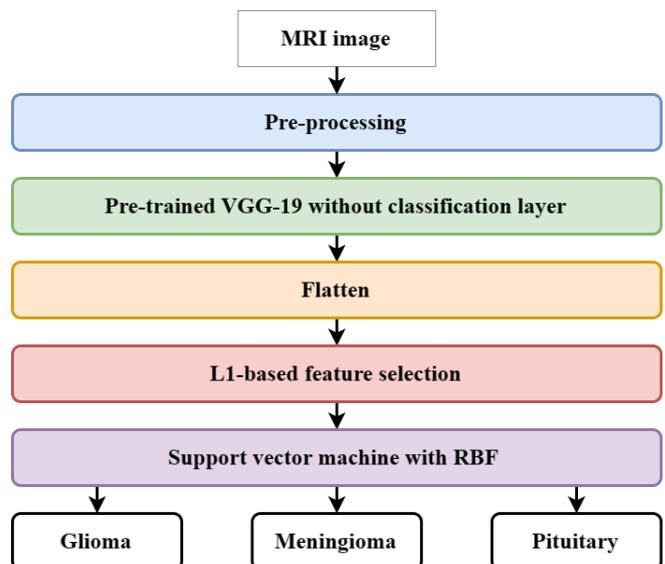


Рис. 1. Блок-схема предлагаемой системы

### A. Набор данных и предобработка

Набор данных изображений мозга, использованный в этом исследовании, как и во всех обсуждаемых работах, представляет собой эталонный набор данных Figshare [10]. Всего было собрано 3064 МРТ-изображения, которые были распределены по трем категориям, представляющим типы опухолей головного мозга. К этим категориям относятся 1426 глиом, 708 менингиом и 930 опухолей гипофиза. Все изображения выполнены в оттенках серого и имеют размеры 512×512.

Поскольку данные позже будут переданы в предварительно обученную глубокую модель, логично и

важно сделать изображения в используемом наборе данных (Figshare) максимально близкими по структуре к набору данных, на котором обучалась модель (ImageNet). Это включает в себя применение следующих операций для каждого изображения:

- Нормализация исходных изображений в оттенках серого по следующей формуле:

$$I_{norm} = [(I - \text{Min}(I)) / (\text{Max}(I) - \text{Min}(I))] \times 255 \quad (1)$$

где  $I$  и  $I_{norm}$  обозначают исходное изображение и выходные данные соответственно.

- Сжатие изображений с использованием алгоритма JPEG для достижения эффективности использования памяти.
- Преобразование изображений набора данных в модель RGB путем присвоения значения интенсивности пикселей в изображении в оттенках серого каждому каналу на выходе RGB.
- Изменение размеров изображений до  $224 \times 224 \times 3$ .
- Каждый цветовой канал центрирован по нулю относительно набора данных ImageNet следующим образом:

$$\begin{aligned} R_{centred} &= R - 123.68 \\ G_{centred} &= G - 116.779 \\ B_{centred} &= B - 103.939 \end{aligned} \quad (2)$$

где 123.68, 116.779 и 103.939 – средние значения цветовых каналов R, G и B в наборе данных ImageNet.

### В. Извлечение признаков

В нашем исследовании мы использовали модель VGG-19 для выполнения задачи извлечения признаков из изображений MPT головного мозга. VGG-19 – это модель CNN, имеющая 19 обучаемых слоев и примерно 144 миллиона параметров. Параметры модели были обучены на наборе данных ImageNet, который содержит 14 миллионов изображений. Архитектура VGG-19 состоит из пяти последовательных блоков свертка-пулинга, за которыми следует полностью связанная нейронная сеть. И первый, и второй блоки содержат по два сверточных слоя с 64 фильтрами для каждого слоя в первом и 128 фильтрами во втором. Третий блок включает четыре сверточных слоя с 256 фильтрами. Четвертый и пятый блоки состоят из четырех сверточных слоев, содержащих 512 фильтров.

Зафиксировав уже обученные параметры VGG-19, эту модель можно использовать для извлечения признаков из любого входного изображения. В нашем подходе классификационная сеть удаляется из VGG-19, а признаки извлекаются из выхода блока 5. Полученные признаки выравниваются (flattened) для формирования одномерного вектора и затем передаются на следующий этап.

### С. Оптимизация признаков

Признаки, извлеченные из предварительно обученной глубокой модели, обычно являются многомерными, неинтерпретируемыми и могут содержать избыточность. Передача этих признаков

непосредственно в классификатор машинного обучения приводит к переобучению и создает сложные границы принятия решений. Использование соответствующего метода оптимизации признаков при сохранении информации может привести к повышению производительности и увеличению обобщения. Далее мы представляем два подхода, которые будут использоваться для оптимизации признаков:

1. *Выбор признаков на основе L1-регуляризации:* Чтобы избежать переобучения, некоторые алгоритмы добавляют в свою функцию оптимизации термин регуляризации, задача которого состоит в том, чтобы ограничить параметры и не допустить их достижения высоких значений. Этого можно достичь, добавив L1-штраф (левый член) к функции потерь логистической регрессии (правый член), чтобы получить следующую задачу неограниченной оптимизации:

$$\min_w \|w\|_1 + C \sum_{i=1}^l \log(1 + \exp(-y_i w^T x_i)) \quad (3)$$

где  $\|w\|_1$  обозначает 1-норму параметров  $w$ ,  $C$  – коэффициент регуляризации,  $l$  – количество выборок в наборе обучающих данных, а  $x$  и  $y$  обозначают входные и выходные данные для выборки  $i$  соответственно.

Роль любого потенциального решателя будет заключаться в нахождении значений параметров  $w$ , которые делают функцию общих потерь, представленную в (3), как можно меньшей, в то время как коэффициент регуляризации контролирует баланс между двумя членами функции. Выбор очень больших значений  $C$  сделает левый член незначительным по сравнению с правым, и усилия решателя будут сосредоточены на минимизации последнего. При выборе очень малого значения  $C$  правый член функции становится пренебрежимо малым по сравнению с левым, и решатель будет контролировать и корректировать член регуляризации, чтобы он был как можно меньшим. Это означает малые или нулевые значения для многих параметров, что естественным образом приводит к сокращению пространства признаков. Оставшиеся неудаленные признаки можно использовать в качестве новых эффективных признаков для обучения другой модели. Использование этого метода для уменьшения размеров требует настройки  $C$  для получения соответствующего количества признаков, которое обеспечивает максимальную производительность, предотвращает переобучение и снижает сложность.

2. *Мера сходства:* В статистике мера сходства – это функция, которая оценивает сходство между двумя точками или векторами. Функция сходства или функция ядра обычно используется для переноса признаков из пространства низкой размерности в пространство высокой размерности, тем самым увеличивая линейную разделимость между классами. Это свойство справедливо, если количество признаков очень мало или, по крайней мере, меньше количества выборок. Напротив, применение ядра к набору данных, в котором количество признаков превышает количество выборок, приведет к уменьшению размерности. В обоих сценариях измерение сходства между каждой парой выборок и использование значений сходства в качестве новых признаков вызовет

преобразование набора данных в другой, где количество признаков равно количеству точек данных. На рис. 2 показан результат применения функции сходства к двум различным наборам данных.

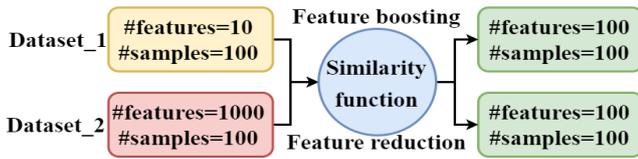


Рис. 2. Механизм функции сходства

В этом контексте, одной из наиболее распространенных функций сходства в машинном обучении, которая будет использоваться в данном исследовании, является радиальная базисная функция. Формулу RBF можно представить следующим образом:

$$K(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (4)$$

где  $x$  и  $x'$  – пара выборок из набора обучающих данных  $X$ , а  $\gamma$  – параметр, контролирующий ширину функции ядра, который можно определить в виде значения масштаба следующим образом:

$$\gamma = 1 / (n\_features \times Var(X)) \quad (5)$$

В уравнении (3) используется целевая переменная  $y$ , и поэтому этот метод можно описать как метод с учителем, тогда как для функции сходства в (4) формула использует только точки данных, и следовательно, его можно рассматривать как метод без учителя.

#### D. Классификация

В нашей системе мы используем хорошо известный алгоритм машины опорных векторов (SVM) для различения типов опухолей головного мозга, выраженных на изображениях МРТ и представленных в виде числовых признаков. Цель SVM – найти гиперплоскость, обеспечивающую наилучшее разделение областей классов данных. Чтобы получить наилучшую производительность, параметр обобщения установлен на разумное значение 5.

### III. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

В этом разделе мы обсуждаем производительность предлагаемой системы, обученной и протестированной в сервисе машинного обучения Jupyter Notebook Colab, где 80 % данных выделяется на обучение, а 20 % на тестирование. Чтобы воспроизвести и улучшить результаты, мы предоставляем исследователям исходный код в виде подробного руководства по следующей ссылке GitHub: [Yasser-A-Nizamli/Brain\\_tumors\\_classification \(github.com\)](https://github.com/Yasser-A-Nizamli/Brain_tumors_classification).

В представленном подходе после обработки изображений МРТ признаки извлекаются из модели VGG-19, выравниваются (flattened) и отправляются на первый раунд оптимизации посредством логистической регрессии с L1-штрафом (L1-lr). Полученные признаки передаются алгоритму SVM с ядром RBF для второго раунда оптимизации перед выполнением классификации. В табл. 1 показаны количество признаков и производительность для каждого выбранного значения  $C$  в функции потерь L1-lr, а на рис. 3 изображена

сглаженная кривая точности в зависимости от количества признаков. Набор значений  $C$  выбран таким образом, чтобы пространство признаков было разделено как можно поровну. Самая высокая точность 98,53 % получена для значений  $C$  50 и 100, что соответствует количеству признаков 7181 и 9251 соответственно. Логично принять меньшее значение для  $C$ , поскольку оно дает меньше признаков и, следовательно, более низкую стоимость при той же точности. Видно, что при выборе большого значения коэффициента регуляризации и начале его уменьшения количество признаков уменьшается, а точность сохраняет те же значения до тех пор, пока не начнет постепенно увеличиваться и не достигнет определенного пика. Так как количество признаков продолжает значительно уменьшаться, точность критически снижается, что указывает на недообучение из-за простоты полученной модели. Стоит отметить, что функция сходства оптимизирует признаки, полученные в результате L1-lr, чтобы они стали равны количеству обучающих выборок.

ТАБЛИЦА I. ПРИЗНАКИ И ПРОИЗВОДИТЕЛЬНОСТЬ ДЛЯ РАЗЛИЧНЫХ ЗНАЧЕНИЙ  $C$

C value	No. features	Accuracy%	F1-score%
0.001	121	94.94	94.28
0.01	665	96.74	96.38
0.1	1234	96.74	96.40
1	2365	97.55	97.23
20	5031	97.71	97.44
50	7181	98.53	98.34
100	9215	98.53	98.34
500	12371	98.21	97.96
600	15323	98.21	97.96
1000	16975	98.04	97.79
2000	18839	98.04	97.79
5000	21318	98.04	97.79

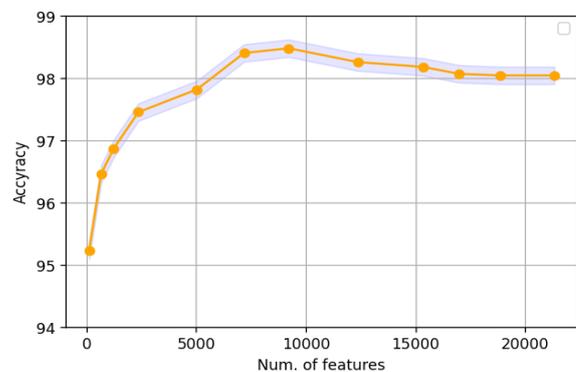


Рис. 3. Кривая точности в зависимости от количества признаков

Производительность модели представлена отчетом о классификации и матрицей ошибок, показанными в табл. 2 и на рис. 4 соответственно. При тестировании нашей системы было получено среднее значение F1 98,34 %, что указывает на высокую производительность по всем классам без смещения. Модель достигла 100 % точности (precision) для глиомы и 100 % полноты (recall) для гипофиза. Это напрямую отражено в матрице ошибок, где мы можем заметить, что ни одна выборка классов менингиомы или гипофиза не была ошибочно предсказана как глиома. Кроме того, все выборки класса гипофиза предсказаны правильно.

ТАБЛИЦА II. ОТЧЕТ О КЛАССИФИКАЦИИ ПРЕДЛОЖЕННОЙ МОДЕЛИ

Class	Precision %	Recall %	F1-score %	Avg-F1%
Meningioma	95.89	97.90	96.89	98.34
Glioma	100	97.95	98.97	
Pituitary	98.33	100	99.16	

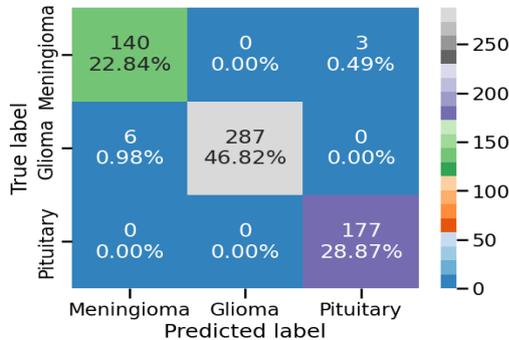


Рис. 4. Матрица ошибок предлагаемой модели

В табл. 3 показано сравнение предлагаемой системы и методов, обсуждавшихся в предыдущем разделе, которые используют тот же набор данных. Несмотря на новизну предложенных моделей, очевидно, что наш подход превосходит их по точности.

ТАБЛИЦА III. СРАВНЕНИЕ ПРЕДЛАГАЕМОЙ МОДЕЛИ И СУЩЕСТВУЮЩЕЙ ЛИТЕРАТУРЫ

Ref., Year	Accuracy%	F1-score%
[2], 2023	96	95.33
[3], 2024	95.10	94
[5], 2023	96	96.92
[6], 2023	95.6	95.07
[7], 2023	96.01	95.68
[8], 2023	–	92.47
[9], 2023	97.60	97.00
Our model	98.53	98.34

#### IV. ЗАКЛЮЧЕНИЕ

В этом исследовании был представлен интеллектуальный подход с целью повышения эффективности обнаружения опухолей головного мозга на изображениях МРТ. В эксперименте после серии

операций обработки численное представление изображений МРТ извлекается с использованием предварительно обученной модели VGG-19. Размеры полученных признаков оптимизированы в ходе двух последовательных этапов: первый был основан на логистической регрессии со штрафом L1, а второй использовал меру сходства по радиальному базису, после чего классификатор опорных векторов взял на себя задачу обнаружения опухолей головного мозга. Для оценки нашей модели мы использовали элементы как отчета о классификации, так и матрицы ошибок. Предложенная модель превзошла аналоги, описанные в научной литературе, достигнув высочайшей точности тестирования.

#### СПИСОК ЛИТЕРАТУРЫ

- [1] Barkade G.D., Bhosale P.S., Shirsath S.K. Overview of brain cancer, its symptoms, diagnosis and treatment // IP International Journal of Comprehensive and Advanced Pharmacology, 2023, vol. 8, no. 3, pp. 159-164.
- [2] Jaspin K., Selvan S. Multiclass convolutional neural network based classification for the diagnosis of brain MRI images // Biomedical Signal Processing and Control, 2023, vol. 83.
- [3] Khan S.U.R., Zhao M., Asif S., Chen X. Hybrid-NET: A fusion of DenseNet169 and advanced machine learning classifiers for enhanced brain tumor diagnosis // International Journal of Imaging Systems and Technology, 2024, vol. 34, no. 1.
- [4] Perkins A., Liu G. Primary brain tumors in adults: Diagnosis and treatment // American family physician, 2017, vol. 93 no. 3, pp. 211-217.
- [5] Biswas A., Islam M.S. A Hybrid Deep CNN-SVM Approach for Brain Tumor Classification // Journal of Information Systems Engineering and Business Intelligence, 2023, vol. 9, no. 1, pp. 1-15.
- [6] Deepak S., Ameer P.M. Brain tumor categorization from imbalanced MRI dataset using weighted loss and deep feature fusion // Neurocomputing, 2023, vol. 520, pp. 94-102.
- [7] Sowrirajan S.R., Balasubramanian S., Raj R.S.P. MRI Brain Tumor Classification Using a Hybrid VGG16-NADE Model // Brazilian Archives of Biology and Technology, 2023, vol. 77.
- [8] Passa R.S., Nurmaini S., Rini D.P. YOLOv8 Based on Data Augmentation for MRI Brain Tumor Detection // Scientific Journal of Informatics, 2023, vol. 10, no. 3.
- [9] Rahman T., Islam M.S. MRI brain tumor detection and classification using parallel deep convolutional neural networks // Measurement: Sensors, 2023, vol. 26.
- [10] Cheng J. brain tumor dataset (2017). Available at: [https://figshare.com/articles/dataset/brain\\_tumor\\_dataset/1512427/5](https://figshare.com/articles/dataset/brain_tumor_dataset/1512427/5) (accessed 26 December 2023).