

Применение трансферного обучения для классификации опухолей головного мозга

Нахида Каража¹, Н. А. Жукова², Яссер Низамли¹

¹Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

²Санкт-Петербургский федеральный исследовательский центр
Российской академии наук СПб ФИЦ РАН

nahidahka@gmail.com, nazhukova@mail.ru, yanizamli@stud.etu.ru

Аннотация. Цель данного исследования является изучение использования методов трансферного обучения для улучшения качества диагностики опухолей головного мозга на магнитно-резонансных томографах. Основное внимание уделяется подходам, основанным на переносе знаний из предварительно обученных нейросетевых архитектур, исследуемых как с точки их клинической значимости, так и со стороны эффективности. В работе проведен анализ предыдущих исследований в области применения искусственного интеллекта в нейровизуализации, а также предложена оригинальная модель классификации с высокой точностью диагностики. Методология данного исследования заключается в применении алгоритма трансферного обучения с архитектурой MobileNetV2, которая была обучена на общедоступном наборе данных, содержащем 7023 изображения МРТ. Модель демонстрирует точность классификации 99, 54, а также высокую precision и recall обнаружения по всем диагностическим категориям. Эксперименты показывают, что модель помогает точно классифицировать МРТ-изображения головного мозга. Обсуждаются также проблемы, которые возникают при внедрении глубокого обучения в медицинскую визуализацию. Приводятся практические рекомендации для будущих исследований.

Ключевые слова: трансферное обучение, классификация опухолей головного мозга, MobileNetV2, сверточные нейронные сети CNN, МРТ

I. ВВЕДЕНИЕ

Опухоли головного мозга возникают в том случае, когда клетки в головном мозге или вокруг него начинают слишком быстро расти, что причиняет ущерб нормальным клеткам и мешает нормальной работе мозга. Согласно отчету GLOBOCAN 2020, зарегистрировано в мире 308 102 новых случая рака головного мозга, который стал причиной 2,5 % всех смертей на всей Земле [1]. Всемирная организация здравоохранения делит глиомы на высокодифференцированные (III и IV степени) и низкодифференцированные (I и II степени). К другим важнейшим типам опухолей относятся аденомы гипофиза, менингиомы, опухоли нервной оболочки и глиомы. Глиомы высокой степени злокачественности растут быстро, а продолжительность жизни у пациентов с ними не превышает двух лет. Глиомы же низкой степени злокачественности, наоборот, растут медленно, а это значит, что их продолжительность жизни будет в

разы больше. Характеристики опухолей (размер, форма, анатомическое расположение) осложняют их обнаружение и хирургическое удаление, что требует их точной классификации с помощью методов сегментации [2].

Чтобы успешно вылечить недуг, его требуется распознать на раннем этапе. Для диагностики нужны неинвазивные визуализирующие методы, такие как МРТ, КТ и ПЭТ [3]. МРТ является одним из самых известных методов визуализации. Для него используются различные углы сканирования и разные техники, но сама процедура длительная, настолько, что для этого нужны большие знания. Совершенствование систем компьютерной диагностики облегчило обнаружение опухолей и снизило уровень смертности. Проблемы больших данных в классификации опухолей решают методы машинного обучения с извлечением признаков, заданных человеком. Способы глубокого обучения улучшают данный этап, находя признаки и зависимости в визуализирующих данных автоматически, через многоуровневый анализ характеристик, что точнее находит и классифицирует недуг.

II. ЛИТЕРАТУРНЫЙ ОБЗОР

В своей области медицины визуализации глубокое обучение произвело настоящую революцию в вопросах извлечения признаков и построения прогнозных моделей, касающихся распознавания опухолей головного мозга, с использованием МРТ. Так, Talo и др. [4] разделили изображения головного мозга на доброкачественные и злокачественные, произведя тестирование на наборе из 613 МРТ-снимков с использованием модели ResNet34 — сверточной нейронной сети (CNN).

Deepak и Ameer [5] использовали уже готовую модель GoogleNet для извлечения признаков из снимков МРТ головного мозга. Они применили классификаторы CNN, SVM, KNN и достигли 98 % успеха в классификации по данным признакам.

Ahmet Inner и др., используя ResNet50 [6], удалили последние пять слоёв и добавили восемь новых, после чего их качество сравнивали с другими давно обученными моделями, такими как GoogleNet, AlexNet и ResNet50. Достигнув 97.2 % точности, улучшенная модель ResNet50 показала многообещающие результаты. С помощью предложенного ими способа машинного обучения достигнута 90 % точность в классификации изображений как нормальных и аномальных.

Данное исследование было поддержано РФФИ, проект No. 22-71-10092-П.

В одном исследовании [7] для сегментации опухолей головного мозга использовалась архитектура U-Net, основанная на ResNet50. Параллельно проходила многоклассовая классификация с использованием таких моделей, как NASNet, DenseNet201 и MobileNetV2. При этом модель NASNet достигла наибольшей точности, равной 99.6 %.

III. МАТЕРИАЛЫ И МЕТОДЫ

A. Dataset

В данной работе был использован общедоступный набор данных MPT опухолей головного мозга, в который вошли всего 7023 MPT-изображения, распределённые на 5712 обучающих и 1311 тестовых изображений, относящихся к 4 классам: глиома, менингиома, опухоль гипофиза и отсутствие опухоли [8]. Чтобы гарантировать надёжное построение и оценку модели, данный набор данных был разделён на три части: обучающую, валидационную и тестовую выборки. В обучающую выборку входило 5712 изображений, 1143 изображения из которых были отложены в качестве валидационной выборки для настройки гиперпараметров. Тестовая выборка состояла из 1311 изображений из оставшихся данных и использовалась для финальной оценки модели, так же для того, чтобы обеспечить объективную её оценку, как показано в табл. 1.

ТАБЛИЦА I. РАСПРЕДЕЛЕНИЕ MPT ИЗОБРАЖЕНИЙ

Class	Training	Validation	Test	Total
Notumor	1,276	319	405	2,000
Meningioma	1,071	268	306	1,645
Glioma	1,056	265	300	1,621
Pituitary	1,166	291	300	1,757
Total	4,569	1,143	1,311	7,023

B. Предварительная обработка данных

С целью добиться целостности входных данных, соответствующих обученной модели MobileNetV2, снимки были нормализованы с использованием средних значений и стандартного отклонения из датасета ImageNet. Чтобы поддержать вычислительную эффективность и в то же время сохранить важные анатомические детали, все фотографии были приведены к размеру 224×224 пикселя.

C. Аугментация данных

Применённая в ходе обучения стратегия аугментации данных была направлена на создание большего разнообразия в наборе данных и повышение его результативности в целом. В частности, использовались следующие методы:

- Вертикальное зеркальное отражение: добавляет вариации в ориентацию изображения, имитируя изменение положения пациента.
- Были использованы два различных преобразования поворота для учёта анатомических различий, часто наблюдаемых на клинических MPT: случайные повороты в $\pm 90^\circ$ и $\pm 30^\circ$.

Данные дополнения были применены после приведения всех изображений к размеру 224×224 пикселей и перед нормализацией. Такая схема позволила

эффективно увеличить объём выборки для обучения, оставаясь при этом в пределах репрезентативности исходных изображений.

D. Предлагаемая модель

Архитектурная основа обрабатываемой модели, предложенной нами системы, — это предварительно обученная сеть MobileNetV2, в которой веса инициализированы с использованием набора данных ImageNet. MobileNetV2 представлена облегчённым вариантом сверточной нейронной сети, спроектированной для осуществления эффективных вычислений, применяющей инвертированные остатки и линейные "узкие места". За счёт произвольной возможности обучения были "открыты" все слои предварительно обученной архитектуры, чтобы обеспечить возможность "тонкой подгонки" под наборы данных MPT головного мозга.

Исходная головка классификатора заменена на произвольный последовательный блок, представляющий собой:

- Dropout (0.3) для регуляризации.
- Линейный слой, уменьшающий размерность признаков с 1280 до 256.
- Активацию ReLU.
- Ещё один слой Dropout (0.2).
- Заключительный линейный слой, проецирующий на 4 выходных класса (отсутствие опухоли, менингиома, глиома, гипофиз).

В табл. II представлены основные гиперпараметры и настройки архитектуры, принятые для обучения, в которые вошли размер входных данных, размер партии, оптимизатор, функции активации, функция классификации и функция потерь, использовавшиеся при обучении.

ТАБЛИЦА II. ПАРАМЕТРЫ РЕАЛИЗАЦИИ МОДЕЛИ

Parameters	Model
Input Layer	$224 \times 224 \times 3$ (RGB)
Batch Size	8 (training), 16 (testing)
Optimizer	Adam
Learning Rate	0.0001
Activation	ReLU (hidden layers), Softmax (output)
Classification function	Softmax
Loss function	Cross-Entropy

IV. МЕТРИКИ ОЦЕНКИ ЭФФЕКТИВНОСТИ

Сравнительная оценка эффективности модели производилась по стандартным метрикам классификации, рассчитанным на тестовом наборе, для определения возможности классифицировать опухоль головного мозга как глиому, менингиому, опухоль гипофиза либо отсутствие опухоли. В частности, исследовали:

- Confusion Matrix: метод для оценки эффективности классификации, включающий истинные положительные результаты (TP), истинные отрицательные результаты (TN), ложные положительные результаты (FP) и ложные отрицательные результаты (FN), как показано на рис. 1 с прогнозами по классам.

- Accuracy: определяет долю правильных прогнозов, рассчитывается как общая точность:

$$(TP + TN) / (TP + TN + FP + FN) \quad (1)$$

- Precision: указывает долю правильных положительных прогнозов, акцентируя внимание на надежности положительных классификаций и рассчитывается как:

$$TP / (TP + FP) \quad (2)$$

- Recall: обозначает долю фактически положительных результатов, успешно распознанных, подчеркивая способность модели обнаруживать злокачественные новообразования.

$$TP / (TP + FN) \quad (3)$$

- F1-Score: является средним гармоническим точности и воспроизводимости, обеспечивающим сбалансированную статистику оценки результатов классификации:

$$2 * [(Precision * Recall) / (Precision + Recall)] \quad (4)$$

V. РЕЗУЛЬТАТЫ

В рамках проведения данного исследования был использован бесплатный графический процессор T4, предоставляемый Google Colab, и обладающий 15 ГБ оперативной памяти GPU и 12,7 ГБ системной оперативной памяти. Предложенная для использования модель MobileNetV2 была обучена на протяжении 20 эпох, что заняло 67 минут. Такая быстрая скорость обучения говорит о готовности модели к внедрению в клиническую практику.

Представленная модель, основанная на модифицированной архитектуре MobileNetV2, показала высокую общую точность 99.54% на тестовой выборке. Это значительно выше многих из лучших методов классификации опухолей головного мозга. В табл. III видно, что показатели производительности также демонстрируют исключительные результаты по всем классам.

ТАБЛИЦА III. ПОКАЗАТЕЛИ ЭФФЕКТИВНОСТИ ПРЕДЛАГАЕМОЙ МОДЕЛИ НА ТЕСТОВОМ НАБОРЕ

	precision	recall	f1-score	Number of images
notumor	1.0000	1.0000	1.0000	405
meningioma	0.9902	0.9902	0.9902	306
glioma	0.9967	0.9933	0.9950	300
pituitary	0.9934	0.9967	0.9950	300
accuracy			0.9954	1311
macro avg	0.9951	0.9950	0.9950	1311
weighted avg	0.9954	0.9954	0.9954	1311

Изображённая на рис. 1 матрица ошибок наглядно показывает, что погрешности зафиксированы только в отдельных случаях: результаты по глиоме, опухоли гипофиза и менингиоме почти безупречны, а при диагностике отсутствия опухоли точность достигла 100 %, это свидетельствует о том, что модель может неплохо разделять чёткие опухолевые паттерны, но из-за визуального сходства некоторые случаи могут быть классифицированы одинаково. Внимательный анализ матрицы показывает следующее распределение ошибок:

Отсутствие опухоли (notumor): все 405 изображений распознаны безошибочно, что свидетельствует о высокой способности модели надежно отличать здоровую ткань от любых новообразований.

Менингиома (meningioma): из 306 тестовых изображений правильно классифицированы 303. Одна опухоль ошибочно отнесена к классу "глиома", а две – к классу "опухоль гипофиза". Глиома (glioma): верно предсказаны 298 образцов из 300. Два изображения ошибочно классифицированы как менингиома.

Опухоль гипофиза (pituitary): правильно распознаны 299 случаев из 300. Одно изображение ошибочно отнесено к менингиоме.

Общее число ошибочных классификаций составило 6 случаев. Тем не менее, крайне низкий уровень межклассовых смещений подтверждает высокую дискриминационную способность предложенной модели на основе MobileNetV2.

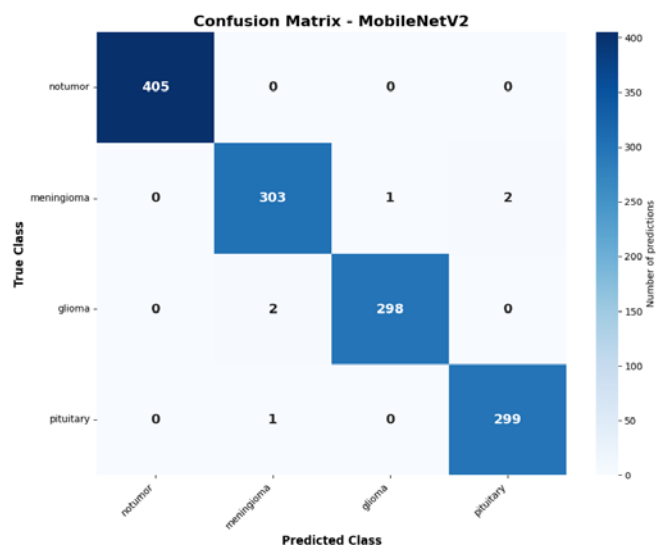


Рис. 1. Матрица ошибок

На рис. 2 представлено изменение точности (accuracy) за 20 эпох и во времени, что демонстрирует планомерное улучшение и сходимость, свидетельствующие об эффективности обучения. На рис. 3 показаны кривые потерь (loss) при обучении и валидации. Оба графика плавно убывают к небольшим значениям, что свидетельствует об отсутствии переобучения модели и наличии стабильной обобщаемости.

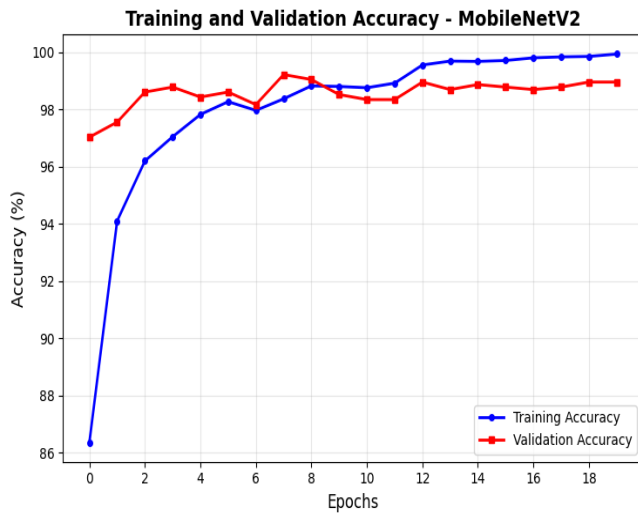


Рис. 2. Изменение точности (accuracy) за 20 эпох и во времени




Рис. 3. Кривые потерь (loss) при обучении и валидации

VI. ОГРАНИЧЕНИЯ И ПЕРСПЕКТИВЫ

Несмотря на многообещающие результаты, в данном исследовании имеются некоторые недостатки, на которые следует обратить внимание.

- Объём и разнообразие набора данных: набор данных включает 7023 МРТ-снимка, однако после разделения на обучающий, валидационный и тестовый наборы его объём по-прежнему остаётся небольшим. Кроме того, данные получены из единственного общедоступного источника, что может не в полной мере отражать разнообразие, присутствующее в реальных клинических условиях, включая различия в производителях сканеров, протоколах визуализации и демографических характеристиках пациентов.
- Отсутствие внешней валидации.
- Модель может классифицировать четыре класса, но не учитывает локализацию опухоли (например, сегментацию) или степень злокачественности, которые очень важны для планирования лечения.

- Ограниченное разнообразие методов аугментации: использовались только повороты и вертикальные зеркальные отражения. Методы, более точно отражающие реальную вариабельность МРТ, включая изменение яркости, масштабирование или упругие деформации, не исследовались.

Для преодоления этих ограничений в дальнейшей работе потребуются более крупные межинституциональные наборы данных, внешняя валидация и расширение модели с включением задач локализации опухолей.

VII. ЗАКЛЮЧЕНИЕ

Проведенная работа, основанная на исследовании современных научных публикаций и опытных данных, доказала высокую эффективность трансферного обучения для задач медицинской визуализации. Использование предварительно обученной на наборе ImageNet архитектуры MobileNetV2 дало возможность опробовать модель на задаче многоклассовой классификации МРТ-изображений головного мозга, выделяя четыре диагностические категории: отсутствие патологии, менингиома, глиома и опухоль гипофиза. Модель почти идеально отделяла классы, без переобучения продемонстрировав точность тестирования 99.54 %. В будущих исследованиях будут рассмотрены различные наборы данных, методы интерпретируемости, такие как Grad-CAM, и сложные стратегии расширения данных, для повышения надёжности и обобщаемости. Область здравоохранения, основанная на ИИ, расширяется, и эта работа вносит свой вклад в её развитие.

СПИСОК ЛИТЕРАТУРЫ

- [1] "Erratum: Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries," *CA a Cancer Journal for Clinicians*, vol. 70, no. 4, p. 313, Apr. 2020, doi: 10.3322/caac.21609.
- [2] S. Z. Kurdi, M. H. Ali, M. M. Jaber, T. Saba, A. Rehman, and R. Damaševičius, "Brain tumor classification using Meta-Heuristic optimized convolutional neural networks," *Journal of Personalized Medicine*, vol. 13, no. 2, p. 181, Jan. 2023, doi: 10.3390/jpm13020181.
- [3] D. Jayadevappa, Ss. Kumar, and D. Murty, "Medical Image Segmentation Algorithms using Deformable Models: A Review," *IETE Technical Review*, vol. 28, no. 3, p. 248, Jan. 2011, doi: 10.4103/0256-4602.81244.
- [4] M. Talo, U. B. Baloglu, Ö. Yıldırım, and U. R. Acharya, "Application of deep transfer learning for automated brain abnormality classification using MR images," *Cognitive Systems Research*, vol. 54, pp. 176–188, Dec. 2018, doi: 10.1016/j.cogsys.2018.12.007.
- [5] S. Deepak and P. M. Ameer, "Brain tumor classification using deep CNN features via transfer learning," *Computers in Biology and Medicine*, vol. 111, p. 103345, Jun. 2019, doi: 10.1016/j.combiomed.2019.103345.
- [6] M. Talo, U. B. Baloglu, Ö. Yıldırım, and U. R. Acharya, "Application of deep transfer learning for automated brain abnormality classification using MR images," *Cognitive Systems Research*, vol. 54, pp. 176–188, Dec. 2018, doi: 10.1016/j.cogsys.2018.12.007.
- [7] T. Sadat *et al.*, "Brain tumor detection and multi-classification using advanced deep learning techniques," *Microscopy Research and Technique*, vol. 84, no. 6, pp. 1296–1308, Jan. 2021, doi: 10.1002/jemt.23688.
- [8] M. Nickparvar, "Brain Tumor MRI Dataset," Kaggle. [Online]. Available: <https://www.kaggle.com/dsv/2645886>.