

# Применение сетей глубокого обучения для выявления рака мозга

Нахида Каража<sup>1</sup>, Н. А. Жукова<sup>2</sup>, Тарек Альнажар<sup>1</sup>

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

<sup>2</sup>Санкт-Петербургский федеральный исследовательский центр  
Российской академии наук СПб ФИЦ РАН

nahidahka@gmail.com, nazhukova@mail.ru, tariq.najjar.7@yandex.com

**Аннотация.** В данной работе рассматривается роль глубокого обучения в диагностике опухолей головного мозга, с акцентом на последние достижения в этой области. Проводится анализ ряда предыдущих исследований, в которых использовались алгоритмы искусственного интеллекта для выявления мозговых опухолей. Представлена модель, основанная на технологиях глубокого обучения для повышения точности диагностики опухолей головного мозга. Модель была обучена на общедоступных наборах данных и продемонстрировала обнадеживающие результаты в выявлении опухолей. В заключении обсуждаются проблемы, связанные с данной технологией, и предлагаются рекомендации для будущих исследований.

**Ключевые слова:** глубокое обучение, искусственный интеллект, диагностика опухоли головного мозга, сверточные нейронные сети, трансферное обучение, МРТ головного мозга

## I. ВВЕДЕНИЕ

Опухоль головного мозга — это масса аномальных клеток, которые разрастаются в структурах центральной нервной системы. Эти опухоли могут быть доброкачественными или злокачественными. Иногда для обнаружения опухоли проводят биопсию мозга, однако это делается редко из-за сложности доступа к опухоли и небезопасности процедуры. Магнитно-резонансная томография (МРТ) является одним из наиболее распространенных методов обнаружения опухолей головного мозга благодаря своей точности и низкому риску. Было проведено много исследований в области классификации изображений мозга с использованием как традиционных методов, так и технологий машинного обучения и глубокого обучения (DL), таких как сверточные нейронные сети (CNN). В то время как методы машинного обучения требуют ручной генерации признаков для классификации, в сверточных нейронных сетях CNN нет необходимости выбирать признаки, поскольку нейронные сети автоматически идентифицируют их. Стоит отметить, что размер обучающего набора данных существенно влияет на признаки, извлекаемые сверточными нейронными сетями.

Искусственный интеллект (ИИ) — область информатики, целью которой является создание машин, способных имитировать человеческий интеллект. ИИ в здравоохранении использует передовые алгоритмы и программное обеспечение и включает обучение на основе данных, обоснование информации и принятие

решений. Исследования в области искусственного интеллекта активизировались в различных медицинских специальностях, таких как радиология, визуализация, телемедицина и электронные медицинские карты. Для медицинских работников ИИ служит мощным инструментом для принятия более обоснованных решений, экономии времени, сокращения затрат и минимизации человеческих ошибок. Это также повышает точность диагностики, улучшает планы лечения и помогает в поиске новых лекарств [1].

Глубокое обучение — это более продвинутая ветвь машинного обучения. Оно имитирует принятие решений человеком с помощью нейронных сетей. Его способность обрабатывать огромные объемы данных и выявлять сложные закономерности делает его очень важным для медицинской визуализации, диагностики и предиктивной аналитики.

Сверточная нейронная сеть (CNN, или ConvNet) — это хорошо известный алгоритм глубокого обучения, который позволяет модели научиться классифицировать объекты непосредственно на основе входных данных, таких как изображения, видео, текст или звук. CNN особенно полезны для обнаружения шаблонов на изображениях, позволяющих идентифицировать объекты, лица и окружение. Эти сети обучаются непосредственно на основе данных изображений, используя изученные шаблоны для классификации изображений и устраняя необходимость ручного выбора признаков. CNN незаменимы в задачах, требующих распознавания объектов и компьютерного зрения, например, в самоуправляемых автомобилях и для программах распознавания лиц. CNN можно либо создать с нуля, либо использовать предварительно обученную модель с заданным набором данных, такой выбор зависит от задачи. Использование предварительно обученных моделей оказалось очень важным для распознавания изображений. Они более доступны для использования, поскольку их архитектура, по сути, «бесплатна». Кроме того, они дают лучшие результаты и требуют меньше времени на обучение.

## II. ЛИТЕРАТУРНЫЙ ОБЗОР

Классификация опухолей головного мозга крайне важна для их оценки опухолей и выбора планов лечения в зависимости от их типа опухоли. Опухоли головного мозга обнаруживаются с помощью различных методов нейровизуализации. Однако чаще всего используется МРТ, поскольку оно обеспечивает лучшее качество изображения и не использует ионизирующее излучение.

Глубокое обучение, направление машинного обучения, показывает стабильно высокие результаты, особенно в задачах классификации и обнаружения. Последние достижения в области глубокого обучения и трансферного обучения позволили значительно повысить точность и эффективность классификации опухолей головного мозга на основе МРТ-изображений.

Ye и др. [2] предложили гибридную структуру CNN-генетического алгоритма (GA) для обнаружения опухолей, интегрирующую многофазный метод главных компонент (MPCA) для извлечения признаков и искусственные нейронные сети (ANN) для классификации. Несмотря на их инновационность, их зависимость от ручной предварительной обработки (например, выравнивание гистограммы, операторы эрозии) приводит к вычислительным издержкам.

Shamshad и др. [3] сравнили три предварительно обученные модели (VGG-16, MobileNet, ResNet-50) на наборе данных из 3064 изображений МРТ. VGG-16 достигла самой высокой точности (97.2%) и скорости, хотя ее большое количество параметров создает риск переобучения на меньших наборах данных.

Krishnapriya и Karuna [4] подчеркнули компромисс между точностью и вычислительными затратами в трансферном обучении, отметив длительное время обучения и дефицит данных как критические узкие места. В этом исследовании классификация выполняется на наборе данных из 305 изображений МРТ мозга с и без опухолей, используются предварительно обученные модели. Модель VGG-19 продемонстрировала наибольший успех с точностью 99,48%.

Talukder и др. [5] доработали ResNet50V2 для многоклассовой классификации опухолей, добившись наилучшей точности (98,2%), но подчеркнув необходимость использования изображений высокого разрешения и архитектурных инноваций. Исследование показало, что ResNet50V2 превосходит другие модели и существующие методы по точности. Отсутствие более четких изображений и улучшенной архитектуры глубокого обучения (DL) является основным ограничением данного исследования, не позволяющим добиться еще более высоких результатов.

### III. МАТЕРИАЛЫ И МЕТОДЫ

#### A. Dataset

База данных проекта содержит 3000 изображения, исследование использует общедоступный набор данных Br35N Brain Tumor Detection 2020 из Kaggle [6], включающий 3000 T1-взвешенных контрастных МРТ-сканирований (1500 с опухолью, 1500 без опухоли). Данные были разделены на 80% обучающих (2400 изображений) и 20% тестовых (600 изображений) со стратификацией для сохранения баланса классов.

#### B. Архитектура модели

В данной работе используется CNN модель, которая включает три основных блока сверточных слоев с возрастающей размерностью фильтров (32-32-64) и ядром 3×3, что позволяет последовательно выявлять иерархические признаки – от простых границ до сложных шаблонов. Каждый сверточный слой использует ReLU как функцию активации для введения нелинейности и сопровождается операцией макспулинга

(2×2) для пространственного уменьшения размерности и повышения инвариантности к малым смещениям. Особое внимание уделено инициализации весов методом he\_uniform, что способствует устойчивости обучения глубокой сети. На этапе классификации тензор признаков преобразуется в одномерное представление (Flatten) и проходит через полносвязный слой из 64 нейронов с регуляризацией Dropout (0.5), что существенно снижает риск переобучения. Финальный классификатор реализован одним нейроном с сигмоидной активацией, обеспечивающим вероятностную оценку принадлежности к целевому классу. Информация о гиперпараметрах, связанных с моделью, приведена в табл. 1.

ТАБЛИЦА I. ПАРАМЕТРЫ РЕАЛИЗАЦИИ МОДЕЛЕЙ

Параметры	Модель
Input Layer	(64, 64, 3)RGB
Batch Size	16
Optimizer	Adam
Activation	ReLU/ Sigmoid
Classification function	Sigmoid
Loss function	binary_crossentropy

### IV. МЕТРИКИ ОЦЕНКИ ЭФФЕКТИВНОСТИ

Для всесторонней оценки качества классификации, в данной работе наряду с метрикой AUC ROC (площадь под кривой ошибок) дополнительно применялись такие показатели, как общая точность (Accuracy), Precision, Recall (полнота), F1-score и анализ матрицы ошибок (confusion matrix). Для более комплексного анализа эти метрики дополняются кривой ROC, отражающей зависимость TPR (True Positive Rate) от FPR (False Positive Rate) при варьировании порога классификации, дополняется этими метриками для более комплексного анализа. Общая точность, рассчитываемая как отношение всех верных предсказаний к общему количеству примеров. Precision (отношение TP к сумме TP и FP) характеризует точность предсказания положительного класса, в то время как recall (отношение TP к сумме TP и FN) показывает способность модели находить все релевантные случаи. F1-score, являющаяся гармоническим средним precision и recall, обеспечивает сбалансированную оценку качества классификации. Матрица ошибок наглядно демонстрирует распределение правильно и ошибочно классифицированных примеров по всем классам, что особенно важно для задач медицинской диагностики, где критически значимы как ложноположительные, так и ложноотрицательные результаты. Такой комплексный подход к оценке, включающий как общие (accuracy, AUC ROC), так и класс-специфичные метрики (precision, recall, F1-score), позволяет не только определить общую эффективность модели, но и детально проанализировать ее поведение для каждого класса в отдельности, таким образом учитывая специфику медицинских данных и строгие требования к диагностической точности.

### V. РЕЗУЛЬТАТЫ

Как показано на рис. 1 и 2, Анализ результатов обучения модели показывает высокую эффективность предложенной архитектуры CNN в задаче бинарной классификации медицинских изображений. На графиках изменения точности (Accuracy) и потерь (Loss) отчетливо прослеживается устойчивая сходимости модели: точность (training accuracy) на данных,

использующихся во время обучения, монотонно возрастает с 0.68 до 0.99, а во время проверки (validation accuracy) – с 0.81 до 0.97, демонстрируя отсутствие переобучения. Параллельно наблюдается значительное снижение значений потерь – во время обучения уменьшаются с 0.59 до 0.02, а во время проверки – с 0.44 до 0.12, что свидетельствует о хорошей способности модели к обобщению. Особого внимания заслуживает минимальный разрыв (около 2%) между финальными значениями тренировочной и валидационной точности, указывающий на оптимальный баланс между обучением и обобщающей способностью. Полученные метрики, в частности валидационная точность (validation accuracy) 97% на последней эпохе, подтверждают практическую применимость модели для автоматизированной диагностики патологий. Сходимость графиков к 10-й эпохе позволяет сделать вывод о достаточности проведенного обучения без необходимости дополнительных итераций.

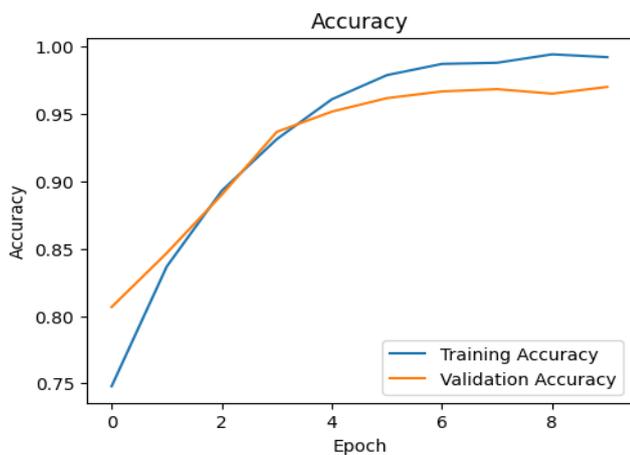


Рис. 1. Точность

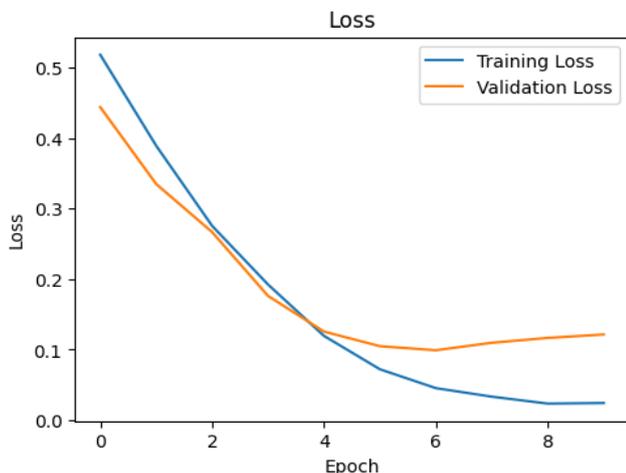


Рис. 2. Потеря

На рис. 3 показана Матрица ошибок (Confusion Matrix), матрица ошибок отражает работу модели в диагностике опухолей мозга. Модель верно определила 299 случаев без опухоли (истинные отрицательные) и 283 случая с опухолью (истинные положительные). Однако были 14 ложно-положительных ошибок (модель ошибочно обнаружила опухоль) и 4 ложно-отрицательных ошибок (модель пропустила реальную опухоль).

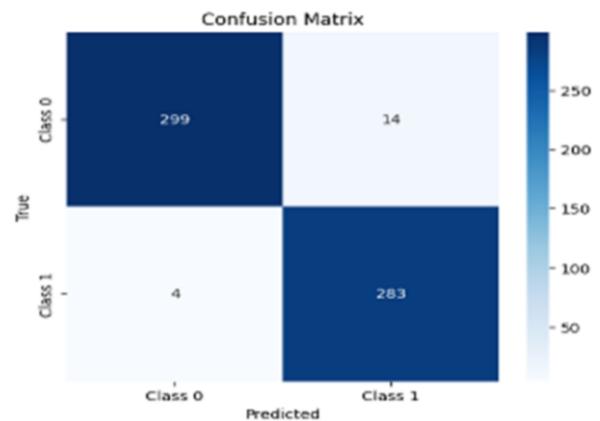


Рис. 3. Confusion matrix

На рис. 4 представлен график ROC-кривой (Receiver Operating Characteristic). Кривая близка к левому верхнему углу, что свидетельствует о высокой предсказательной способности модели, с площадью под кривой (AUC) 0.99, что значительно превышает уровень случайного угадывания (пунктирная линия)

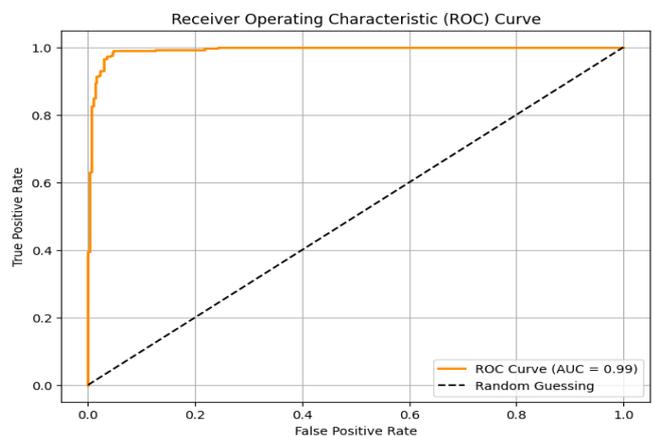


Рис. 4. Receiver Operating Characteristic ROC

Общая точность (Accuracy) в данном случае 97%, демонстрирует высокую эффективность модели в целом. В табл. 2 представлена информация о precision, recall, f1-score для каждого класса.

ТАБЛИЦА II. РЕЗУЛЬТАТЫ ОБУЧЕНИЯ

	Precision	Recall	F1-Score	Количество изображений
Class 0 (Без опухоли)	0.99	0.96	0.97	313
Class 1 (С опухолью)	0.95	0.99	0.97	287

## VI. ЗАКЛЮЧЕНИЕ

В данном исследовании был проведен обзор литературы и предыдущих соответствующих исследований. Несколько последних исследований показали эффективность использования моделей сверточных нейронных сетей (CNN) и трансферного обучения в анализе медицинских изображений. Была разработана CNN модель для обнаружения опухолей головного мозга на МРТ-изображениях. Модель достигла точности 97% с замечательным балансом

между точностью классификации (precision) и отзывом (recall) для обоих классов, продемонстрировав способность работать с данными сбалансированно, без предвзятости к определенному классу. Эффективность модели можно повысить, расширив набор данных для улучшения обобщающей способности модели и изучив более продвинутое архитектуры нейронных сетей. Данный проект станет частью более крупного проекта, в котором, помимо определения наличия опухоли, будет определена площадь ее присутствия и тип опухоли, а затем предложена стратегия лечения. Хотя большие модели, такие как [3][4], могут достигать точности на 1–2 % выше, их структурная сложность и вычислительные требования делают их непрактичными для повседневных клинических применений. В данной работе представлено сбалансированное решение между производительностью, технической осуществимостью и стабильной работой с наборами данных среднего размера.

#### СПИСОК ЛИТЕРАТУРЫ

- [1] Bajwa J., Munir U., Nori A., Williams B. Artificial Intelligence in Healthcare: Transforming the Practice of Medicine. // *Future Healthcare Journal*. 2021. Т. 8. №. 2. P. e188–e194.
- [2] Ye J., Zhao Z., Ghafourian E., Tajally A., Alkhazaleh H., Lee S. Optimizing the topology of convolutional neural network (CNN) and artificial neural network (ANN) for brain tumor diagnosis (BTD) through MRIs // *Heliyon*. 2024. Т. 10. E35083.
- [3] Shamshad N., Sarwr D., Almogren A., Saleem K., Munawar A., Ur Rehman A., Bharany S. Enhancing Brain Tumor Classification by a Comprehensive Study on Transfer Learning Techniques and Model Efficiency Using MRI Datasets // *IEEE Access*. 2024. Т. 12. С. 100407-100418.
- [4] Krishnapriya S., Karuna Y. Pre-trained deep learning models for brain MRI image classification // *Frontiers in Human Neuroscience*. Т. 17. С. 1150120
- [5] Talukder M.A., Islam M.M., Uddin M.A., Akhter A., Pramanik M.A.J., Aryal S., Almoyad M.A.A., Hasan K.F., Moni M.A. An efficient deep learning model to categorize brain tumor using reconstruction and fine-tuning. // *Expert Systems With Applications*. 2023. Т. 230. С. 120534.
- [6] Hamada A. Br35H: Brain Tumor Detection 2020 (2020). Available at: <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection> (дата обращения: 08.01.2025).