

ПЕРЕДОВЫЕ МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ УЛУЧШЕННОГО ПРОГНОЗИРОВАНИЯ СТАДИЙ БОЛЕЗНИ АЛЬЦГЕЙМЕРА

ADVANCED MACHINE LEARNING TECHNIQUES FOR ENHANCED PREDICTION OF ALZHEIMER'S DISEASE STAGES

**Mohamed Douache
M. Ronkin**

Summary. This paper explores the use of deep learning and machine learning models to predict Alzheimer's disease stages, aiming to improve accuracy and diagnostic quality. We compared three CNN models, K-Nearest Neighbors (KNN), Temporal Convolutional Networks (TCN), and XGBoost for classifying brain scan images of different Alzheimer's stages. CNN models were optimized for spatial feature extraction, KNN was used for instance classification, TCN captured temporal patterns, and XGBoost enhanced prediction performance through ensemble methods. Our goal was to identify the most accurate and computationally efficient model for clinical applications. Experimental results highlight the strengths and weaknesses of each approach, helping to determine the best algorithms for reliable Alzheimer's detection.

Keywords: Alzheimer's disease, CNN, K-Nearest Neighbors (KNN), Temporal Convolutional Networks (TCN), XGBoost, machine learning, deep learning, brain scan classification, medical image analysis, prediction accuracy, ensemble learning, diagnostic tools.

Мохамед Дуаш

Аспирант, Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина
douache.mohamed@gmail.com

Ронкин Михаил

Доцент, Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина
m.v.ronkin@urfu.ru

Аннотация. В статье рассматривается применение моделей глубокого и машинного обучения для прогнозирования стадий болезни Альцгеймера с целью повышения точности и качества диагностики. Сравнены три модели CNN, K-ближайшие соседи, временные сверточные сети (TCN) и XGBoost для классификации стадий изображений мозга. CNN модели оптимизированы для извлечения пространственных особенностей, KNN используется для классификации, TCN — для анализа временных закономерностей, а XGBoost улучшает предсказания с помощью ансамблевого метода. Целью было найти наиболее точную и вычислительно эффективную модель. Результаты экспериментов показывают сильные и слабые стороны каждого подхода для выбора лучших алгоритмов для клинической практики.

Ключевые слова: болезнь Альцгеймера, CNN, метод K-ближайших соседей (KNN), временные сверточные сети (TCN), XGBoost, машинное обучение, глубокое обучение, классификация при сканировании мозга, анализ медицинских изображений, точность прогнозирования, ансамблевое обучение, диагностические инструменты.

Введение

Прогресс в области искусственного интеллекта и машинного обучения открывает новые возможности для диагностики сложных заболеваний, таких как болезнь Альцгеймера. Современные подходы к анализу медицинских изображений включают использование мощных алгоритмов глубокого обучения и методов классификации, способных значительно повысить точность и надежность диагностики. В данной статье исследуются и сравниваются несколько методов классификации стадий болезни Альцгеймера, включая сверточные нейронные сети (CNN), метод K-ближайших соседей (KNN), временные сверточные сети (TCN) и XGBoost. Основное внимание уделяется разработке и оптимизации моделей для извлечения пространственно-временных особенностей данных, а также выявлению наиболее эффективного подхода для применения в клинической практике.

Цель исследования

Основной целью исследования было повышение точности машинного обучения для стадирования болезни Альцгеймера. Работа фокусируется на сравнении алгоритмов для выявления наиболее эффективного подхода к классификации стадий заболевания — от нормальной когнитивной функции до поздних стадий.

Особое внимание уделено сверточным нейронным сетям (CNN) и их сравнению с другими методами, с акцентом на настройку гиперпараметров и архитектурные корректировки для обеспечения точных прогнозов с минимальными ошибками [1].

Исследование также направлено на баланс между точностью и вычислительной эффективностью, чтобы разработать модели, применимые в клинической практике. Дополнительно оно изучает влияние предварительной обработки данных и демографических разли-

чий пациентов на эффективность моделей, гарантируя надежность прогнозов для различных наборов данных. Цель — создать универсальный инструмент для ранней диагностики и мониторинга болезни Альцгеймера.

Обзор литературных источников

Болезнь Альцгеймера исследуется с использованием алгоритмов машинного и глубокого обучения. Различные подходы [2] применяются для анализа изображений мозга, направленных на улучшение диагностики. Так, Сарачага и др. [3] с помощью методов глубокого обучения достигли 88 % точности на наборе данных OASIS. Судхарсан и Тайламбал [4] продемонстрировали 75 % точности, анализируя ADNI с использованием методов MO. Хелали и др. [5] достигли 93 % точности для многоклассовой классификации стадий AD, используя сверточные сети. Шакила Башир и др. [6] показали 92 % на OASIS с помощью глубоких сетей. Мартинес-Мурсия и др. [7] применили сверточные автокодировщики, обеспечив 80 % точности для данных ADNI. Праджапати и др. [8] использовали бинарную классификацию на глубоких сетях и достигли 85 % точности. Эти исследования подчеркивают эффективность современных методов анализа изображений в диагностике заболеваний мозга.

На Рис 1. представлены исследования и их средняя точность классификации на основе анализа наборов данных OASIS и ADNI. Видно, что самые высокие резуль-

таты достигают исследования Хелали и др. (93%) и Шакила Башир и др. (92%), использующие глубокие нейронные сети и сверточные сети для много классовых стадий болезни Альцгеймера.

Методология

Методы сбора данных

В этой работе мы используем набор данных изображений сканирования мозга, собранных из различных источников, для анализа болезни Альцгеймера. Набор данных, используемый в этой работе, организован в pandas DataFrame из 843 записей, каждая запись представляет собой одно независимое изображение сканирования мозга и соответствующую ему метку. Метки указывают на различные стадии болезни Альцгеймера: «AD» — болезнь Альцгеймера, «CN» — когнитивно нормальная, «LMCI» — позднее легкое когнитивное нарушение и «EMCI» — раннее легкое когнитивное нарушение. Распределение изображений по этим категориям демонстрирует значительный дисбаланс: в общей сложности 573 изображения обозначены как «AD», а по 90 изображений — как «CN», «LMCI» и «EMCI». Это расхождение в количестве изображений в каждой категории отражает фактическую распространенность стадий болезни Альцгеймера, где «AD» встречается значительно чаще. Эти изображения находятся в структурированном формате, включая пути к файлам для расположения каждого

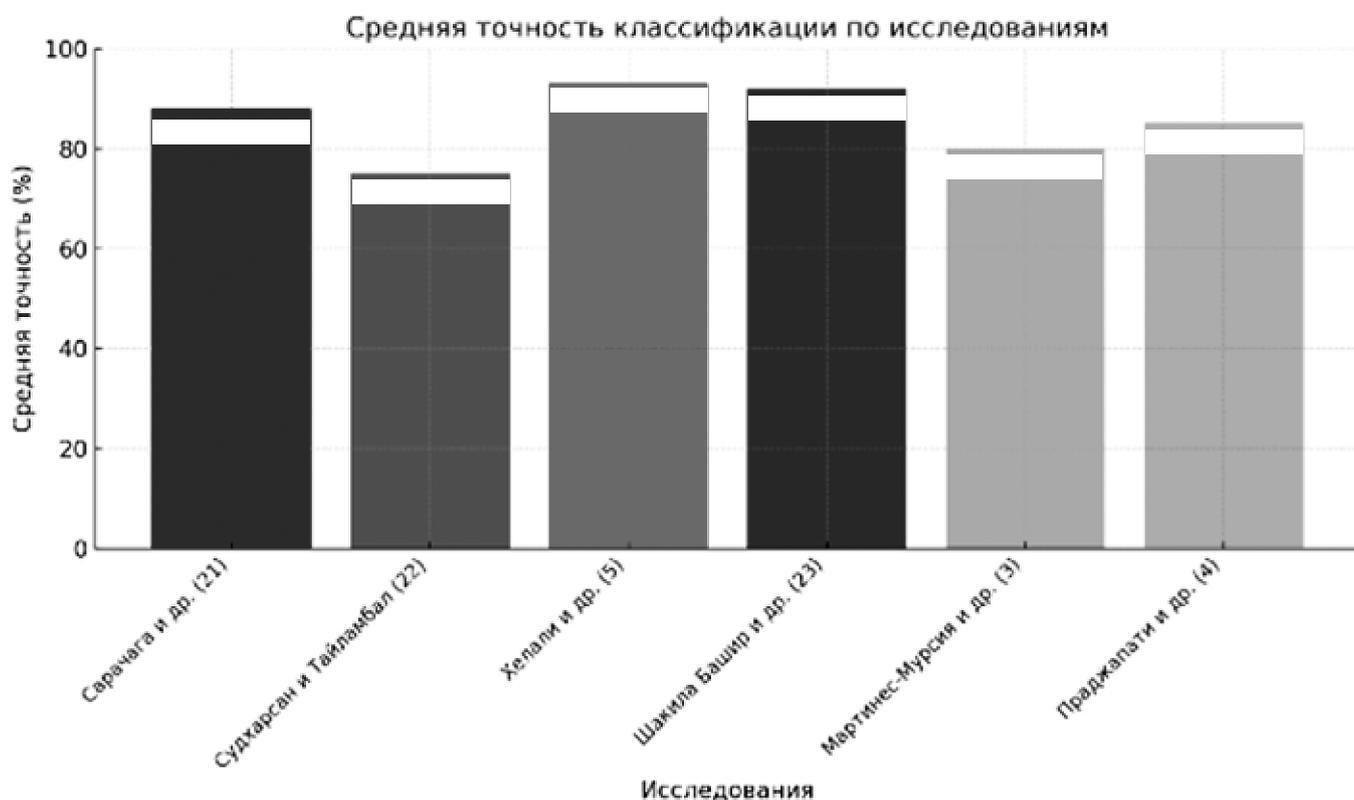


Рис. 1. Средняя точность классификации моделей МО и ДО для диагностики болезни Альцгеймера

из них на облачном диске. Этот набор данных незаменим при построении и оценке различных моделей машинного обучения, ориентированных на классификацию и прогнозирование прогрессирования болезни Альцгеймера. Исчерпывающий процесс сбора гарантирует, что набор данных точно представляет многие стадии заболевания; однако его несбалансированное распределение классов требует вмешательства на этапе обучения модели с помощью подходящих методов обработки данных, таких как повторная выборка или взвешивание классов.

Методы анализа данных

Наш анализ данных использует как качественные, так и количественные методы для извлечения действенных идей из набора данных. Качественный анализ фокусируется на выявлении тенденций и повторяющихся закономерностей в циклах спроса, предпочтениях потребителей и скачках продаж в секторе видеоигр. Количественный анализ, включая прогнозирование временных рядов и методы машинного обучения, применяется к данным о продажах для прогнозирования будущего

спроса, оптимизации уровней запасов и минимизации ситуаций дефицита и избытка запасов. Объединяя эти аналитические подходы, мы стремимся создать предиктивную модель ИИ, адаптированную к уникальным характеристикам спроса и продаж видеоигр, предлагая практические стратегии для оптимизации запасов в этой отрасли.

В данной таблице представлено четкое и краткое описание набора данных, включая его структуру, содержание и проблемы, связанные с его использованием.

Описание алгоритма

Алгоритм описывает разработку модели сверточной нейронной сети (CNN) для многоклассовой классификации медицинских изображений, таких как МРТ головного мозга, для диагностики болезни Альцгеймера. Предварительная обработка данных включает разделение на обучающие, проверочные и тестовые наборы для сбалансированного представления классов. Архитектура CNN включает сверточные слои для захвата иерархических признаков, слои максимального объединения для уменьшения размерности и полносвязный слой для классификации с использованием softmax. Модель использует категориальную перекрестную энтропию и оптимизируется с помощью Adam. Она эффективно выявляет тонкие признаки, отличающие стадии болезни Альцгеймера, и показывает хорошие результаты на данных проверки и тестирования [9–14].

Таблица 1.

Резюме набора данных

Аспект	Описание
Общее количество изображений	843
Столбцы данных	изображение (путь к файлу изображения) и метка (стадия заболевания)
Формат пути к файлу изображения	Хранится в виде строковых объектов, представляющих пути к файлам изображений на облачном диске.
Этикетки	AD (болезнь Альцгеймера), CN (когнитивно нормальный), LMCI (позднее легкое когнитивное нарушение), EMCI (раннее легкое когнитивное нарушение)
Количество изображений в категории	— AD: 573 — CN: 90 — LMCI: 90 — EMCI: 90
Распределение данных	Несбалансированно, с большим количеством изображений в категории «AD» по сравнению с другими стадиями
Цель	Разработать и оценить модели машинного обучения для классификации и прогнозирования стадий болезни Альцгеймера.
Вызовы	Несбалансированный набор данных, который может повлиять на производительность модели; требует обработки с помощью таких методов, как повторная выборка или взвешивание классов

Шаг 1: Предобработка данных

1. Разделение данных:
 - Разделить набор данных на обучающий, проверочный и тестовый, обеспечив правильную стратификацию для поддержания баланса классов.
2. Отображение форм наборов данных:
 - Проверить и подтвердить формы обучающего, проверочного и тестового наборов.

Шаг 2: Инициализация модели

1. Определение архитектуры CNN:
 - Добавить несколько сверточных слоев с активацией ReLU для извлечения признаков, затем слои максимального пула для уменьшения размерности.
 - Преобразовать выход в одномерный вектор и добавить полностью связанный слой с 1024 единицами и активацией ReLU.
 - Включить слой исключения для предотвращения переобучения, а затем слой softmax для многоклассовой классификации с 4 выходами (стадии болезни Альцгеймера).
2. Вывод сводки модели:
 - Отобразить информацию о модели, включая типы слоев, выходные формы и количество параметров.

Subject ID	Image ID	Description	Modality	Resolution	Orientation	Path
50002	029831	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50003	029832	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50004	029833	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50005	029834	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50006	029835	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50007	029836	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50008	029837	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50009	029838	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50010	029839	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50011	029840	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50012	029841	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50013	029842	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50014	029843	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50015	029844	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50016	029845	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50017	029846	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50018	029847	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50019	029848	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...
50020	029849	MP-RAGE	T1	1.0	Sagittal	/content/drive/MyDrive/alzheimer_dataset/data_AD/...

(A)



(B)

Рис. 2. Веб-сайт набора данных

Источник: А. Таблица изображений IDA, В. Просмотрщики и загрузки изображений IDA

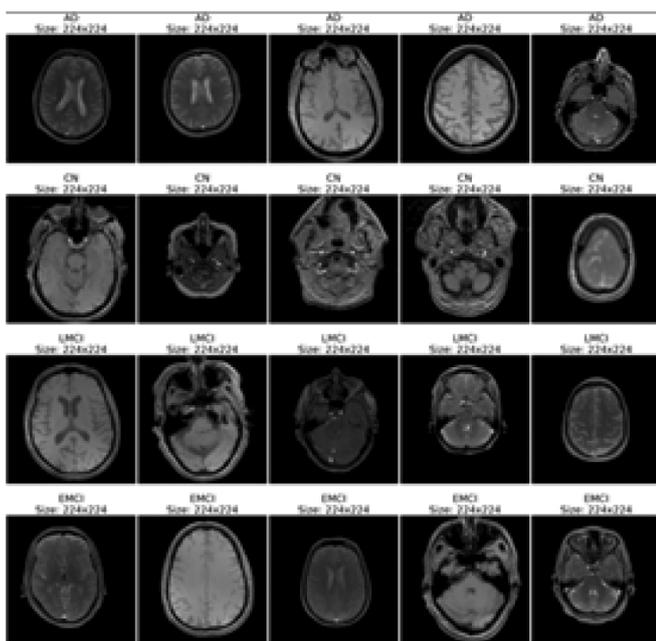


Рис. 3. Визуализация выборки данных

Шаг 3: Обучение модели

1. Компиляция и обучение модели:
 - Использовать категориальную кросс-энтропию как функцию потерь и оптимизатор Adam с коэффициентом обучения 0,001.
 - Обучить модель с размером партии 32 на определенное количество эпох с использованием обучающих и проверочных данных.

Шаг 4: Оценка модели

1. Оценка производительности модели:
 - Оценить производительность модели на тестовом наборе с использованием таких метрик, как точность, точность, отзыв и F1-оценка.

Шаг 5: Оптимизация и улучшения

1. Применение пакетной нормализации и ранней остановки:

- Добавить слой пакетной нормализации после каждого сверточного слоя для ускорения сходимости и стабильности обучения.
- Реализовать раннюю остановку для предотвращения переобучения, отслеживая потери на валидации и останавливая обучение, если они не улучшаются.

Набор данных состоит из 843 образцов, где каждый образец соответствует изображению сканирования мозга, помеченному в соответствии со стадией болезни Альцгеймера. Два столбца в наборе данных:

- **изображение:** В этом столбце содержатся пути к файлам изображений сканирования мозга.
- **этикетка:** В этом столбце указана соответствующая метка для каждого изображения, указывающая стадию болезни Альцгеймера (например, AD для болезни Альцгеймера).

Обе колонки имеют объект тип данных, то есть они содержат строки. В наборе данных нет пропущенных значений, а общий объем памяти, используемый для

Таблица 2.

Руководитель DataFrame

Индекс	Путь к изображению	Этикетка
0	/content/drive/MyDrive/alzheimer_dataset/data_AD/...	ОБЪЯВЛЕНИЕ
1	/content/drive/MyDrive/alzheimer_dataset/data_AD/...	ОБЪЯВЛЕНИЕ
2	/content/drive/MyDrive/alzheimer_dataset/data_AD/...	ОБЪЯВЛЕНИЕ
3	/content/drive/MyDrive/alzheimer_dataset/data_AD/...	ОБЪЯВЛЕНИЕ
4	/content/drive/MyDrive/alzheimer_dataset/data_AD/...	ОБЪЯВЛЕНИЕ

хранения этой информации, составляет приблизительно 13,3 КБ.

Результаты и обсуждения

Мы оценили такие показатели производительности, как точность, прецизионность, отзывчивость и показатель F1, используя 5-кратный подход перекрестной проверки с использованием таких моделей, как Деревья решений, CNN, случайные леса, KNN и TCN. Оценки эффективности, как бинарные, так и многоклассовые, были детализированы с использованием матриц путаницы для устранения переобучения и настройки параметров. Для точного прогнозирования и дифференциации лю-

Таблица 3.

Точность и значения оценки F1 Модель CNN

Эпохи	Точность	Потеря	Val_accuracy	Val_loss
0	0,296758	1.373442	0,508721	1.312698
1	0,503117	1.140661	0,619186	0,945076
2	0,659601	0,846996	0,732558	0,770621
3	0,770574	0,625195	0,808140	0,596971
4	0,899002	0,343187	0,819767	0,569558
5	0,908354	0,268179	0,941860	0,265598
6	0,951995	0,142669	0,904070	0,255353
7	0,979426	0,081131	0,953488	0,146223
8	0,991895	0,033950	0,953488	0,163020
..
19	1.000000	0,000677	0,970930	0,138240

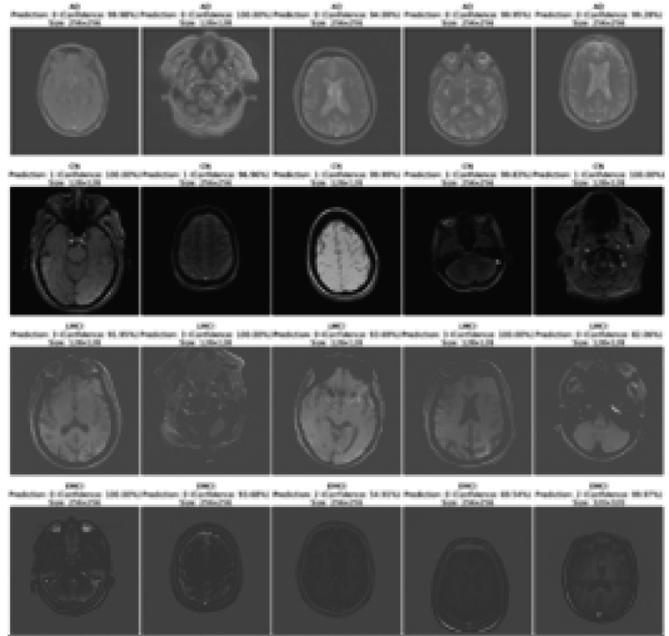


Рис. 5. Прогнозирование болезни Альцгеймера с использованием стандартной модели CNN

дей с болезнью Альцгеймера был разработан классификатор машинного обучения. Напомним, что чувствительность измерялась, а точность определяла количество людей, правильно идентифицированных как не страдающие болезнью. Показатель F1 позволил получить сбалансированную оценку точности и запоминаемости.

Наша модель CNN достигла впечатляющей точности в 99 % при классификации изображений, продемонстрировав свою способность эффективно изучать сложные закономерности и особенности на основе данных. Эта исключительная производительность подчеркивает надежность модели и ее пригодность для задач, связанных с обработкой изображений, требующих точности

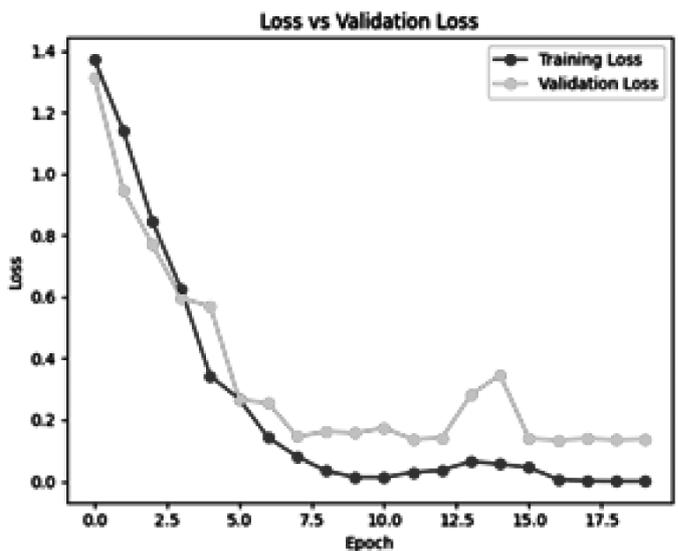
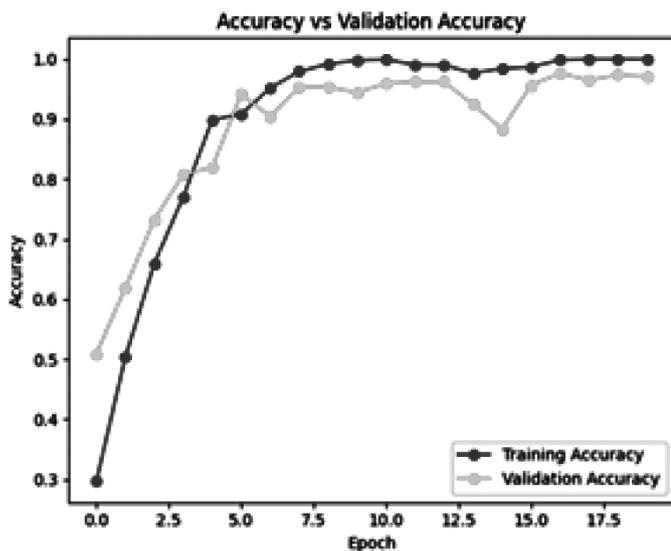


Рис. 4. Точность и значения оценки F1 Модель CNN

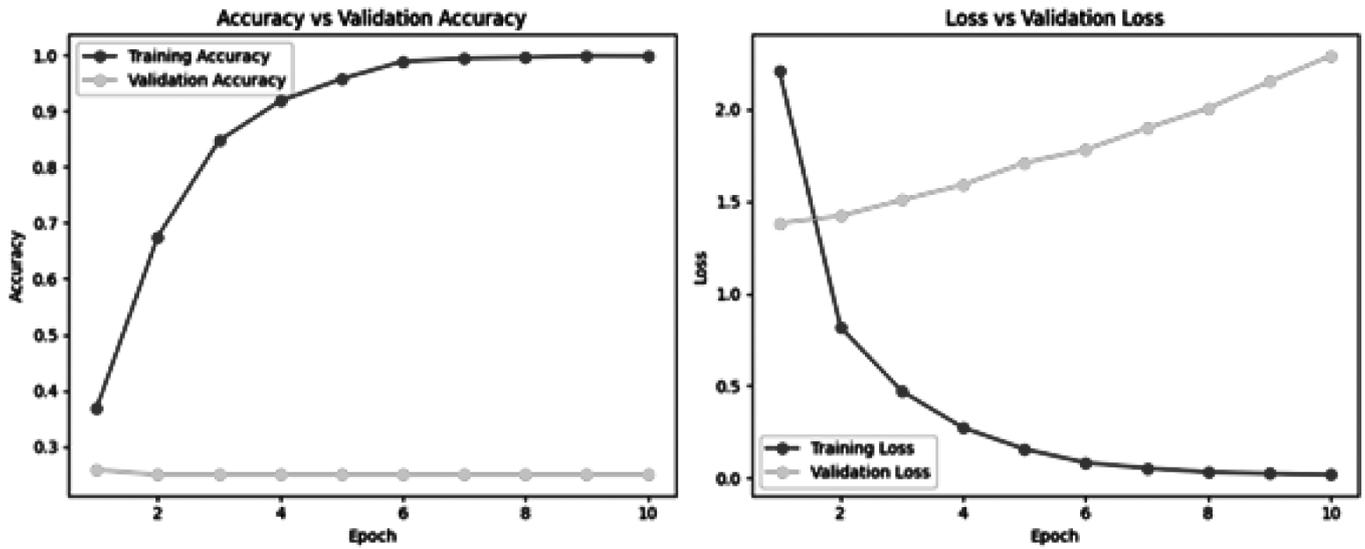


Рис. 6. Точность и оценка F1 оптимизированы для CNN с уменьшенными параметрами

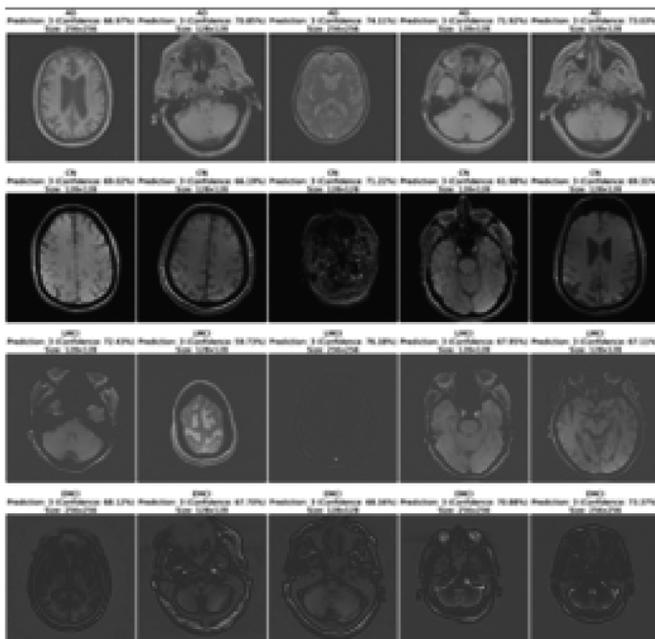


Рис. 7. Прогнозирование болезни Альцгеймера с использованием стандартной модели CNN. Оптимизированная CNN с сокращенными параметрами и эффективности. Результаты классификации, включая стадию заболевания, дают клиницистам ценную информацию, позволяющую лучше понимать прогрессирующие болезни Альцгеймера и управлять им.

График показывает точность и потери модели CNN, обученной на данных о болезни Альцгеймера. Модель демонстрирует низкую точность проверки (~0,25) при высокой точности обучения (~0,95), а также рост потерь проверки при снижении потерь обучения, что указывает на переобучение. Вероятной причиной является сокращение параметров в оптимизированной модели, что

могло снизить её способность учитывать сложные закономерности данных. Кроме того, классификация болезни Альцгеймера по медицинским изображениям сложна из-за минимальных изменений в структурах мозга, что требует более мощных моделей или улучшенной предварительной обработки данных.

Точность обучения быстро выросла в первые три эпохи, достигнув 0,67, и стабилизировалась на уровне 0,99 к десятой эпохе. Точность проверки осталась низкой (~0,25) на протяжении всего обучения, указывая на явное переобучение. Потери обучения снизились до 0,81 во второй эпохе и стабилизировались на уровне 0,05, тогда как потери проверки увеличились до 2,28 к десятой эпохе.

Модель слишком хорошо адаптируется к обучающим данным, но не обобщает на новые данные, вероятно, из-за сложности модели или недостаточного объема данных. Слой глобального усреднения (GAP), заменяющий полностью связанные слои, оказался малоэффективным, что требует анализа причин переобучения. Для улучшения производительности рекомендуется увеличить размер данных, использовать регуляризацию и уменьшить сложность модели. Результаты подчеркивают важность анализа кривых обучения для предотвращения переобучения и оптимизации модели.

Заключение

При оценке различных моделей для прогнозирования стадии болезни Альцгеймера модель CNN достигла наивысшей точности в 98 %, за ней следует CNN с меньшим количеством слоев и планировщиком скорости обучения, которая достигла 97 %. Это демонстрирует способность архитектуры CNN захватывать сложные шаблоны, даже если она оптимизирована для простоты.

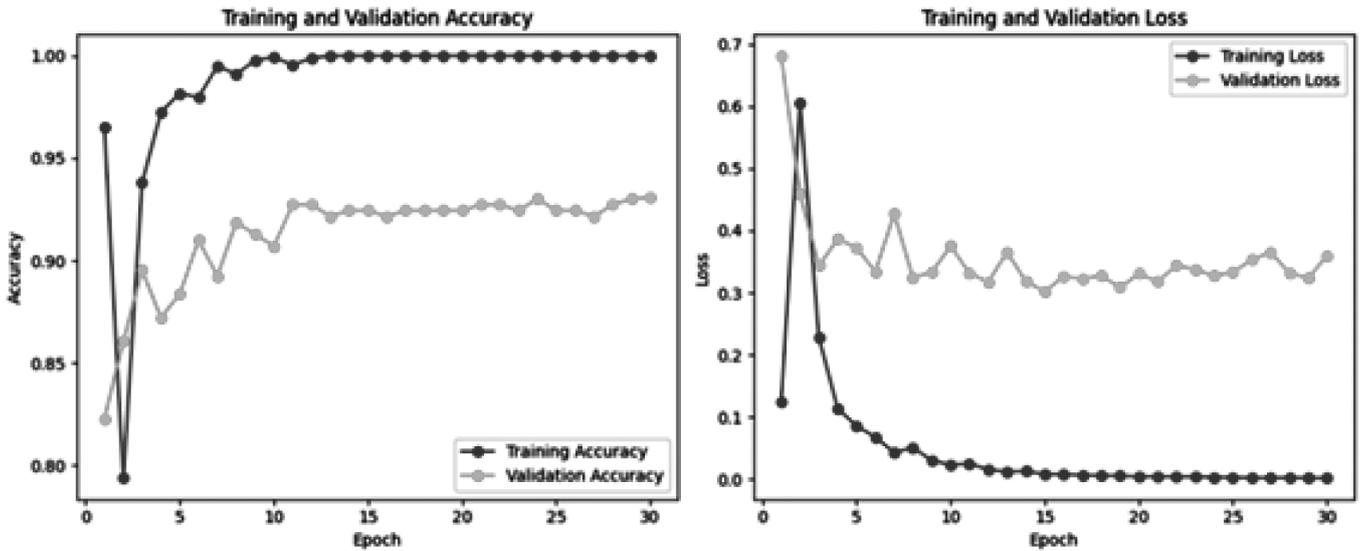


Рис. 8. Точность и оценка F1 CNN с глобальным средним объединением

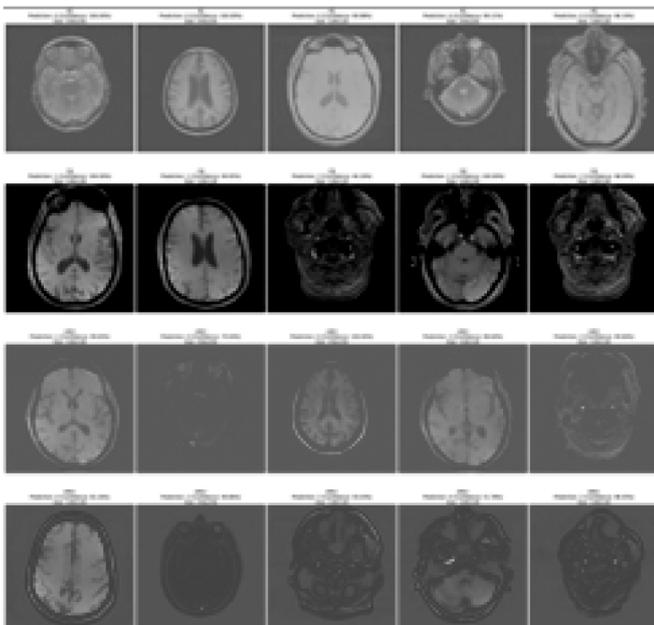


Рис. 9. Прогнозирование болезни Альцгеймера с использованием CNN с глобальным усреднением пула

Оптимизированная CNN, которая включала дополнительную настройку для улучшения производительности, достигла 91 %, показав хороший баланс между вычислительной эффективностью и точностью. Однако CNN с глобальным усреднением пула (GAP) показала немного более низкие результаты в 86 %, что указывает на то, что при снижении переобучения она также могла поставить под угрозу некоторый уровень точности модели. Нако-

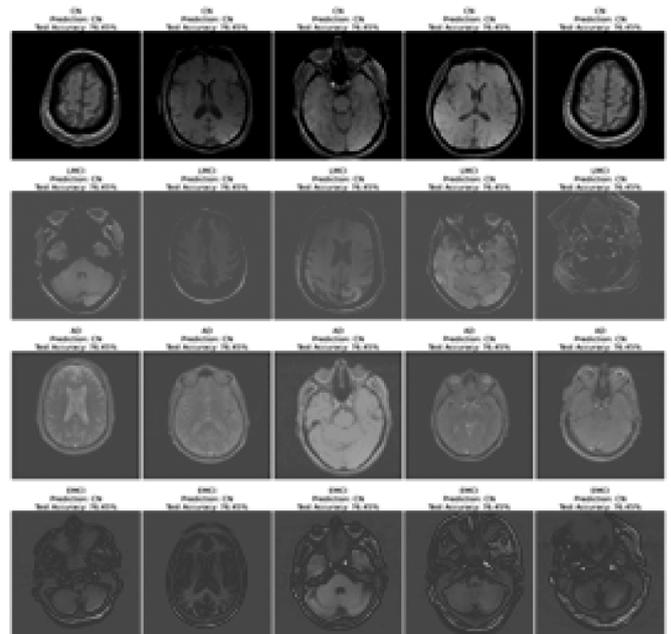


Рис. 10. Прогнозирование болезни Альцгеймера с использованием KNN

нец, модель K-ближайших соседей (KNN) показала сравнительно более низкую точность в 76 %, что отражает ее ограничения в обработке сложных данных на основе изображений по сравнению со сверточными моделями. Это общее сравнение подчеркивает силу методов глубокого обучения, в частности CNN, в задачах классификации изображений высокой размерности, таких как прогнозирование стадии болезни Альцгеймера.

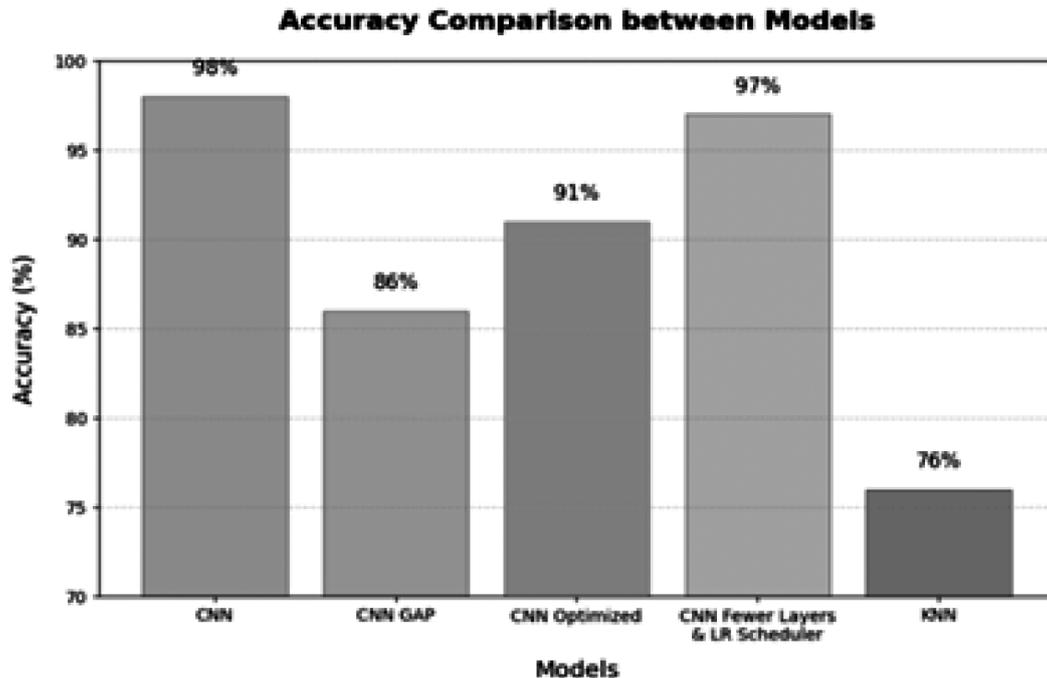


Рис. 11. График сравнения моделей

ЛИТЕРАТУРА

- Сивакани Г.А., Ансари Р. Структура машинного обучения для внедрения болезни Альцгеймера. *Int Conferen Commun Signal Process.* (2020) 12:588–92. 10.1109/ICCSP48568.2020.9182220 [CrossRef] [Google Академия]
- Хан П., Кадер М.Ф., Ислам С.Р., Рахман А.Б., Камал М.С., Тоха М.У. и др. Подходы к машинному обучению и глубокому обучению для диагностики заболеваний мозга: принципы и последние достижения. *IEEE Access.* (2021) 9:37622–55. 10.1109/ACCESS.2021.3062484 [CrossRef] [Google Академия]
- Мартинес-Мурсия Ф.Дж., Ортис А., Горрис Дж.М., Рамирес Дж., Кастильо-Барнс Д. Изучение многообразной структуры болезни Альцгеймера: подход глубокого обучения с использованием сверточных автоэнкодеров. *IEEE J Biomed Health Inform.* (2020) 24:17–26. 10.1109/JBHI.2019.2914970 [PubMed] [CrossRef] [Google Академия]
- Праджapati Р., Кхатри У., Кwon ГР. «Эффективный двоичный классификатор на основе глубокой нейронной сети для классификации болезни Альцгеймера», В: Международная конференция по искусственному интеллекту в информации и коммуникации (ICAIIIC). (2021), стр. 231–234. [Google Академия]
- Хелали Н.А., Бадави М., Хайкал А.У. Метод глубокого обучения для раннего выявления болезни Альцгеймера. *Cogn Computing.* (2021) 21:1–17. 10.1007/s12559-021-09946-2 [Бесплатная статья PMC] [PubMed] [CrossRef] [Google Академия]
- Яффе К. Модифицируемые факторы риска и профилактика деменции: каковы последние данные. *JAMA Intern Med.* (2018) 178:281–2. 10.1001/jamainternmed.2017.7299 [PubMed] [CrossRef] [Google Академия]
- Ливингстон Г., Соммерлад А., Оргета В., Костафреда С.Г., Хантли Д. и др. Профилактика, вмешательство и уход за больными деменцией. *The Lancet.* (2017) 390:2673–73. 10.1016/S0140-6736<17>31363-6 [PubMed] [CrossRef] [Google Академия]
- O'Donnell C.A., Manera V., Köhler S., Irving K. Продвижение изменяемых факторов риска деменции: есть ли роль для общей практики? *British J General Pract.* (2015) 65:567–8. 10.3399/bjgp15X687241 [Бесплатная статья PMC] [PubMed] [CrossRef] [Google Академия]
- Сулейман Н., Абдулсахиб Г., Халаф О., Мохаммед М.Н. «Эффект использования различных распространений протоколов маршрутизации OLSR и DSDV», в трудах Международной конференции IEEE по структурированию и моделированию интеллектуальных систем. (2014), стр. 540–5. [Google Академия]
- Deckers K., van Boxtel M.P., Schiepers O.J., de Vugt M., Muñoz Sánchez J.L., Anstey K.J. и др. Целевые факторы риска для профилактики деменции: систематический обзор и консенсусное исследование Delphi на основе доказательств из наблюдательных исследований. *Int J Geriatric Psychiatry.* (2015) 30:234–46. 10.1002/gps.4245 [PubMed] [CrossRef] [Google Академия]
- Schiepers O.J., Köhler S., Deckers K., Irving K., O'donnell C.A., Van den Akker и др. Образ жизни для здоровья мозга (LIBRA): новая модель профилактики деменции. *Int J Geriatric Psychiatry.* (2018) 33:167–75. 10.1002/gps.4700 [PubMed] [CrossRef] [Google Академия]
- Vos S.J., Van Boxtel M.P., Schiepers O.J., Deckers K., De Vugt M., Carrière I., et al. Модифицируемые факторы риска для профилактики деменции в среднем возрасте, пожилom возрасте и у самых пожилых: валидация индекса LIBRA. *J Alzheimer's Dis.* (2017) 58:537–47. 10.3233/JAD-161208 [PubMed] [CrossRef] [Google Академия]
- Осам Халаф И., Гайда М., Абдулсахиб Д. Энергоэффективная маршрутизация и надежный протокол передачи данных в WSN. *Int J Adv Soft Comput Applicat.* (2020) 12:45–53. [Google Академия]
- Национальные академии наук Инженерия и медицина. Профилактика когнитивного снижения и слабоумия: путь вперед. Лондон: The National Academies Press; (2018). [PubMed] [Google Академия]