

<https://doi.org/10.21869/2223-1536-2025-15-4-192-210>

УДК 004.89+93

Оценка эффективности модели глубокого обучения на основе EfficientNetB3 для дифференциальной диагностики стадий болезни Альцгеймера

А. В. Киселев¹ ✉, Е. А. Кулешова¹, М. О. Таныгин¹,
П. М. Свинухов¹, И. А. Халин¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: kiselevalexey1990@gmail.com

Резюме

Цель исследования – оценка эффективности применения модифицированной архитектуры EfficientNetB3 на основе методов трансферного глубокого обучения и ранней остановки в системах поддержки принятия врачебных решений для дифференциальной диагностики стадий болезни Альцгеймера.

Методы. Для проведения экспериментальных исследований был сформирован набор данных для обучения, проведена нормализация и аугментация данных. Выполнена программная реализация модифицированной нейросетевой архитектуры EfficientNetB3 с применением методов трансферного глубокого обучения и ранней остановки на языке программирования Python. Проведено обучение нейросетевой модели.

Результаты. Оценка эффективности классификации, обученной нейросетевой модели, проводилась с помощью метрик Recall, Precision, Specificity, F1-мера и AUC-ROC. Анализ значений этих метрик показал, что результаты, продемонстрированные модифицированной архитектурой EfficientNetB3, характеризуются выраженной асимметрией и указывают на узкоспециализированный характер данной модели. С одной стороны, модель проявила себя как эффективный инструмент для диагностики стадии умеренной деменции, продемонстрировав максимально возможное значение AUC. С другой стороны, эффективность классификации для остальных классов значительно ниже (значения AUC для классов «Отсутствие деменции», «Очень лёгкая деменция» и «Лёгкая деменция» равны 0,87, 0,86 и 0,95 соответственно).

Заключение. Исходя из результатов проведенного анализа можно сделать вывод, что основная практическая ценность данной модификации архитектуры EfficientNetB3 заключается в ее использовании в составе гетерогенных ансамблей или каскадных системах диагностики для верификации конкретной стадии болезни Альцгеймера – умеренной деменции с целью повышения общей эффективности системы. Это указывает на перспективность дальнейших исследований в области создания узкоспециализированных архитектур, способных решать конкретные подзадачи с высокой точностью, превосходящей универсальные, но менее сфокусированные подходы.

Ключевые слова: болезнь Альцгеймера; нейросетевая модель; трансферное обучение; глубокое обучение; классификация; дифференциальная диагностика.

Конфликт интересов: Авторы декларируют отсутствие конфликта интересов, связанных с публикацией данной статьи.

Для цитирования: Оценка эффективности модели глубокого обучения на основе EfficientNetB3 для дифференциальной диагностики стадий болезни Альцгеймера / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин, П. М. Свинухов, И. А. Халин // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2025. Т. 15, № 4. С. 192–210. <https://doi.org/10.21869/2223-1536-2025-15-4-192-210>

Поступила в редакцию 29.10.2025

Подписана в печать 27.11.2025

Опубликована 26.11.2025

Evaluation of the effectiveness of a deep learning model based on EfficientNetB3 for differential diagnosis of Alzheimer's disease stages

Alexey V. Kiselev¹ ✉, Elena A. Kuleshova¹, Maxim O. Tanygin¹,
Pavel M. Svinuhov¹, Igor A. Khalin¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: kiselevalexey1990@gmail.com

Abstract

The purpose of the research is evaluation of the effectiveness of the modified EfficientNetB3 architecture based on transfer deep learning and early stopping methods in medical decision support systems for differential diagnosis of Alzheimer's disease stages.

Methods. To conduct experimental studies, a training dataset was generated, normalized, and augmented. A modified EfficientNetB3 neural network architecture was implemented using transfer learning and early stopping methods in Python. The neural network model was trained.

Results. The classification performance of the trained neural network model was assessed using the Recall, Precision, Specificity, F1-score, and AUC-ROC metrics. Analysis of these metrics revealed that the results achieved by the modified EfficientNetB3 architecture are characterized by significant asymmetry, indicating the highly specialized nature of this model. On the one hand, the model proved to be an effective tool for diagnosing moderate dementia, demonstrating the highest possible AUC value. On the other hand, classification performance for the remaining classes was significantly lower (AUC values for the "No Dementia," "Very Mild Dementia," and "Mild Dementia" classes were 0,87, 0,86, and 0,95, respectively).

Conclusion. Based on the results of the analysis, it can be concluded that the primary practical value of this modification of the EfficientNetB3 architecture lies in its use in heterogeneous ensembles or cascaded diagnostic systems for verifying a specific stage of Alzheimer's disease – moderate dementia – in order to improve the overall system efficiency. This points to the potential for further research in the area of creating highly specialized architectures capable of solving specific subproblems with high accuracy, surpassing general-purpose but less focused approaches.

Keywords: Alzheimer's disease, neural network model, transfer learning, deep learning, classification, differential diagnosis.

Conflict of interest: The authors declares no conflict of interest related to the publication of this article.

For citation: Kiselev A.V., Kuleshova E.A., Tanygin M.O., Svinuhov P.M., Khalin I.A. Evaluation of the effectiveness of a deep learning model based on EfficientNetB3 for differential diagnosis of Alzheimer's disease stages. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2025;15(4):192–210. (In Russ.) <https://doi.org/10.21869/2223-1536-2025-15-4-192-210>

Received 29.10.2025

Accepted 27.11.2025

Published 26.12.2025

Proceedings of the Southwest State University. Series: Control, Computer Engineering,
Information Science. Medical Instruments Engineering. 2025;15(4):192–210

Введение

Нейродегенеративные заболевания представляют собой гетерогенную группу прогрессирующих патологий центральной нервной системы, ключевым патогенетическим механизмом которых является постепенная гибель нейронов. К наиболее распространённым заболеваниям этой категории относят болезнь Альцгеймера, болезнь Паркинсона, боковой амиотрофический склероз и болезнь Хантингтона. Несмотря на общее нейродегенеративное происхождение, эти заболевания существенно различаются по клинической картине, локализации патологического процесса, скорости прогрессирования и молекулярно-генетическим механизмам [1].

Болезнь Альцгеймера (БА) представляет собой одну из наиболее распространённых форм деменции, сопровождающуюся необратимым прогрессирующим нейродегенеративным процессом, приводящим к снижению когнитивных функций, утрате памяти и дезорганизации повседневной активности. Согласно данным из Всемирного отчета о болезни Альцгеймера Международной организации по борьбе с болезнью Альцгеймера за 2021 г., число людей, живущих с деменцией, превышает 55 млн, из которых более 60% приходится на БА. Прогнозируется, что к 2050 г. эта цифра достигнет 152,8 миллионов [2]. Основной фактор риска – пожилой возраст, однако на ранних стадиях БА может проявляться и у пациентов среднего возраста, особенно

в случае генетической предрасположенности. В настоящее время ранняя диагностика БА остаётся затруднённой вследствие неспецифичности симптоматики на начальных стадиях, а также ограниченного доступа к дорогостоящим и инвазивным методам подтверждения диагноза [3].

Несвоевременное выявление заболевания существенно снижает эффективность возможной терапии, замедляющей прогрессирование симптомов. В связи с этим возрастает потребность в разработке инструментов ранней неинвазивной диагностики, способных выявлять патологические изменения в мозге до наступления выраженной клинической картины. Магнитно-резонансная томография (МРТ) представляет собой один из ключевых методов нейровизуализации, применяемый для диагностики и мониторинга нейродегенеративных заболеваний. МРТ позволяет визуализировать структурные изменения головного мозга, в частности, атрофию гиппокампа, парагиппокампальных извилин, коры медиальных височных долей, а также изменения в белом веществе [4].

В условиях постоянного роста числа пожилого населения и, как следствие, распространённости нейродегенеративных расстройств, особенно актуальным становится вопрос создания автоматизированных методов обработки и анализа нейровизуализационных данных, которые смогут повысить эффективность ранней диагностики данного вида заболеваний и сократить временные затраты

медицинского персонала. Также это может помочь справиться с недостатком специалистов и повысить доступность качественной диагностики для населения, не зависящей от географического положения или экспертного опыта отдельных врачей [5]. В основе таких методов чаще всего лежат алгоритмы машинного обучения, способные выявлять патологические изменения при анализе медицинских изображений [6]. Благодаря способности к автоматическому извлечению пространственных признаков, сверточные нейронные сети (СНС) демонстрируют высокую эффективность при обработке и анализе медицинских изображений, в т. ч. полученных с помощью МРТ [7].

В работе [8] авторами был проведен анализ эффективности применения различных нейросетевых моделей (НМ) для обнаружения болезни Альцгеймера на МРТ-снимках. Авторы обучили и сравнили шесть моделей СНС с использованием трансферного обучения (ТО): VGG19, ResNet101, EfficientNetB3, MobileNetV2, InceptionV3 и DenseNet121 – для классификации МРТ-снимков по 2 классам (БА и отсутствие болезни). В результате экспериментов НМ InceptionV3 показала наиболее высокое значение метрики оценки качества классификации Ассигасу, равное 99,2%.

В работе [9] авторы предложили модель для диагностики БА на основе СНС, обученную на МРТ-снимках. Обученная модель показала значение метрики Ассигасу, равное 95, при

классификации МРТ-снимков по 4 классам (предеменция, ранняя деменция, умеренная деменция и без заболевания).

Однако стоит отметить, что при расчете метрики оценки качества классификации Ассигасу не учитываются штрафы за ложноотрицательные ошибки, также стоит отметить, что данная метрика имеет низкую чувствительность к дисбалансу классов, что, в свою очередь, весьма критично для задач медицинской диагностики [10].

В работе [11] авторы провели ряд экспериментов с различными архитектурами СНС и использованием метода ТО для решения задачи классификации МРТ-снимков по 3 классам (БА, легкие когнитивные нарушения и когнитивная норма). В ходе экспериментов авторы использовали четыре модели без применения ТО и четыре модели с применением ТО. Модели на основе СНС дали информацию о выявленном типе деменции, уровне достоверности диагноза и тепловых картах, созданных с помощью градиентно-взвешенного картирования активации классов (Grad-CAM), выделяющих патологически пораженные области мозга. Хотя оба подхода продемонстрировали высокую эффективность классификации, модели на основе ТО показали лучшие результаты (макрое среднее значение метрики AUC-ROC по трем классам, равное 0,86 и 0,97, для показавших лучший результат моделей без использования ТО и с применением ТО соответственно).

Результаты предшествующих исследований указывают на высокий потенциал применения моделей на основе СНС, в частности моделей, основанных на глубоком ТО, для раннего обнаружения и дифференциации нейродегенеративных заболеваний в системах поддержки принятия врачебных решений [12]. Такие системы могут помочь медицинским работникам сократить время диагностики деменции, оптимизировать индивидуальные стратегии управления и лечения для пациентов.

Материалы и методы

Набор данных для обучения был синтезирован на основе изображений из репозитория «Инициативы по нейровизуализации болезни Альцгеймера» (ADNI) [13]. Изначально набор данных содержал 6400 изображений, разделенных на четыре класса: отсутствие признаков деменции (Non Demented), очень лёгкая деменция (Very Mild Demented), лёгкая деменция (Mild Demented) и умеренная деменция (Moderate Demented).

Первичный анализ распределения данных по классам выявил выраженный дисбаланс классов: наиболее многочисленными были классы Non Demented и Very Mild Demented, тогда как класс Moderate Demented оказался существенно менее представленным. Такая диспропорция способна приводить к смещению предсказаний модели в сторону более часто встречающихся классов и затруднить обучение на менее репрезентативных примерах [14]. Для преодоления этой проблемы, а также в целях увеличения объема обучающей выборки и снижения риска переобучения был применён метод аугментации

изображений [15]. С помощью библиотеки Keras была реализована аугментация изображений, включающая следующие операции: случайное вращение в пределах ± 15 градусов, горизонтальное отражение, масштабирование и сдвиги по ширине и высоте до 10%, а также сдвиги по срезу (shearing), что позволило расширить набор данных до 33984 изображений. Все изображения автоматически приводились к размеру 224×224 пикселя, соответствующему входному формату модели EfficientNetB3. Нормализация данных проводилась с использованием функции `efficientnet_preprocess`, обеспечивающей совместимость с предобученными на наборе данных ImageNet слоями модели.

Вместо использования стандартного генератора ImageDataGenerator для поддержки совместимости с текущей версией библиотеки TensorFlow применялись пользовательские генераторы, построенные на API `tf.data.Dataset`, включающие поддержку пакетной загрузки, предварительной обработки, кэширования и буферизации. Для обеспечения возможности масштабируемого использования аппаратных ресурсов, в т. ч. GPU, был использован размер пакета данных (batch size), равный 32. Для разделения исходного массива изображений на обучающую и валидационную выборки использовалось стратифицированное разбиение с отношением 80:20 по каждому классу.

Предлагаемая НМ базируется на методе ТО [16], использующем модифицированную архитектуру EfficientNetB3. В рамках модификации НМ поверх «замороженных» слоев базовой модели были добавлены следующие классификацион-

ные слои: глобальный слой усредняющего пулинга (ГСУП) для уменьшения пространственной размерности признаков, слой пакетной нормализации (СПН) для стабилизации обучения, полносвязный слой (ПС) с 1024 нейронами, а также слой Dropout с коэффициентом 0,5 для предотвращения переобучения путем случайного отключения части нейронов в процессе обучения.

ПС применяется для интеграции и обобщения признаков, извлечённых предыдущими слоями. ПС был добавлен поверх сверточной базы EfficientNetB3 с целью последующей классификации на основе признаков, извлечённых из МРТ-снимка. Для обеспечения нелинейности модели и эффективности обработки градиентов в качестве функции активации используется ReLU.

Пусть входной вектор признаков из предыдущего слоя обозначается как

$$\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^n, \quad (1)$$

где n – размерность входного пространства (например, после слоя GlobalAveragePooling2D она составляет 1536 для EfficientNetB3).

В ПС с $m = 1024$ нейронами выполняются следующие преобразования:

1. Линейная комбинация признаков по

$$z_j = \sum_{i=1}^n w_{ji} x_i + b_j, \quad j = 1, 2, \dots, 1024, \quad (2)$$

где w_{ji} – вес связи между входом i и нейроном j ; x_i – входной вектор признаков; b_j – смещение (bias).

В матричной форме линейная комбинация признаков определяется согласно

$$\mathbf{z} = \mathbf{W}\mathbf{x} + \mathbf{b}, \quad \mathbf{W} \in \mathbb{R}^{1024 \times n}, \quad \mathbf{b} \in \mathbb{R}^{1024}. \quad (3)$$

2. Активация с использованием функции ReLU по

$$a_j = \text{ReLU}(z_j) = \max(0, z_j). \quad (4)$$

В векторной форме выход слоя после активации определяется по

$$\mathbf{a} = \text{ReLU}(\mathbf{z}) \in \mathbb{R}^{1024}. \quad (5)$$

ПС с 1024 нейронами выполняет функцию высокой абстракции – он компонирует представление, полученное после сверточного анализа, в более компактное и классификационно-значимое пространство. Данная размерность выбрана эмпирически как компромисс между выразительностью и числом параметров модели с учетом требований к производительности и ограниченного объема доступных обучающих данных.

Одним из преимуществ ГСУП в контексте модификации НМ является его способность существенно уменьшать число параметров модели, поскольку его применение позволяет избежать использования полносвязных слоев с большим количеством входов. Это особенно важно при обучении модели на ограниченном количестве МРТ-снимков, где избыточные параметры могут привести к переобучению. Кроме того, ГСУП облегчает интерпретацию модели: каждый элемент итогового вектора непосредственно соответствует определенному фильтру признаков, что используется при последующей визуализации тепловых карт (метод Grad-CAM).

В контексте данного исследования ГСУП применяется после финального сверточного блока модели EfficientNetB3.

Он преобразует трехмерную карту признаков в вектор признаков фиксированной длины, который затем подается на выходной слой с функцией активации softmax, производящий вероятностное распределение по классам.

ГСУП представляет собой альтернативу стандартным ПС, обычно применяемым после сверточных блоков нейронной сети, которые увеличивают число параметров модели и тем самым повышают риск переобучения. ГСУП обеспечивает интерпретируемую форму агрегирования пространственной информации по каналам признаков.

Работу ГСУП можно описать следующим образом: на вход подается тензор признаков после сверточных операций, имеющий размерность $H \times W \times C$, где H и W – пространственные размеры (высота и ширина карты признаков), а C – количество каналов. Для каждого канала c (от 1 до C) ГСУП вычисляет среднее значение по всем пространственным координатам этого канала по

$$z_c = \frac{1}{H \cdot W} \sum_{i=1}^H \sum_{j=1}^W x_{i,j,c}, \quad (6)$$

где $x_{i,j,c}$ – значение тензора признаков в позиции (i, j) канала c ; z_c – результирующее скалярное значение, полученное для канала c после применения усредняющего пулинга.

Таким образом, результатом работы ГСУП является одномерный вектор $z = [z_1, z_2, \dots, z_C] \in \mathbb{R}^C$, в котором каждый элемент отражает агрегированную активность соответствующего канала.

В рамках исследования слой BatchNormalization (BN) был добавлен между сверточными и ПС классификатора. Входом в слой BN является мини-

батч из m примеров $x^{(1)}, x^{(2)}, \dots, x^{(m)}$, где каждый элемент $x^{(i)}$ – это скалярное значение активации на выходе предыдущего слоя. Математическая формализация данного слоя выглядит следующим образом:

1. Расчет среднего значения по батчу:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x^{(i)}. \quad (7)$$

2. Расчет дисперсии по батчу:

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x^{(i)} - \mu_B)^2. \quad (8)$$

3. Нормализация каждого значения:

$$\hat{x}^{(i)} = \frac{x^{(i)} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}, \quad (9)$$

где ϵ – небольшая положительная константа для численной устойчивости.

4. Линейное преобразование с обучаемыми параметрами:

$$y^{(i)} = \gamma \hat{x}^{(i)} + \beta, \quad (10)$$

где γ и β – это обучаемые параметры, которые позволяют слою BN масштабировать (изменять разброс) нормализованные данные (γ) и сдвигать (изменять среднее значение) нормализованные данные (β).

Параметры γ и β позволяют слою сохранять представляемость сети (возможность обучиться любому распределению). Если обучение покажет, что исходные ненормализованные данные были полезнее, модель сможет восстановить их масштаб и смещение с помощью этих параметров.

Финальный выходной слой представлял собой ПС с 4 нейронами, соответствующими количеству классов, и

функцией активации Softmax, которая обеспечивает вероятностное распределение принадлежности входного изображения к каждому из четырех классов.

Компиляция модели была выполнена с использованием оптимизатора Adam и начальной скоростью обучения, установленной на уровне 1×10^{-4} . В качестве функции потерь была выбрана категориальная кросс-энтропия (categorical_crossentropy), что является стандартным решением для задач многоклассовой классификации.

Процесс обучения модели управлялся с помощью ряда критериев. Критерием «лучшей» модели служит максимальное значение валидационной точности (val_accuracy), что гарантирует сохранение наиболее эффективной и обобщающей конфигурации весов. ReduceLROnPlateau динамически регулирует скорость обучения. Если валидационная функция потерь (val_loss) не

демонстрирует улучшений в течение 5 последовательных эпох (patience = 5), то скорость обучения автоматически уменьшается на 20% (factor = 0,2), при этом минимальная скорость обучения ограничена значением 1×10^{-6} . Модель прекращает процесс обучения, если валидационная функция потерь (val_loss) не улучшается в течение 10 эпох (patience = 10), после чего веса модели автоматически восстанавливаются до состояния той эпохи, на которой была достигнута лучшая производительность на валидационном наборе.

Также был реализован механизм построения тепловой карты Grad-CAM, визуализирующей область на изображении, оказавшую наибольшее влияние на классификационное решение модели. На рисунке 1 приведен пример классификации и градиентно-взвешенного картирования активации классов (Grad-CAM).

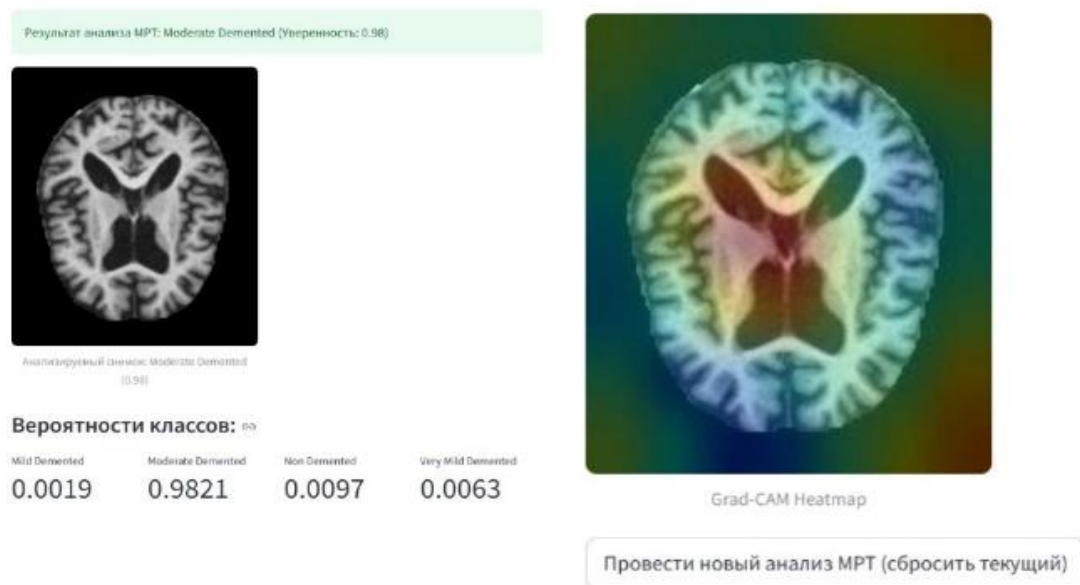


Рис. 1. Пример классификации и градиентно-взвешенного картирования активации классов (Grad-CAM)

Fig. 1. An example of classification and gradient-weighted class activation mapping (Grad-CAM)

Тепловая карта генерируется с использованием градиентной информации с последнего сверточного слоя модели и объединяется с оригинальным изображением.

Результаты и их обсуждение

На основе полученных данных о количестве ошибок первого и второго рода с помощью метрик Recall, Precision, Specificity F1-меры и AUC-ROC была проведена оценка эффективности классификации, обученной НМ по четырем классам: отсутствие признаков деменции (Non Demented), очень лёгкая деменция (Very Mild Demented), лёгкая

деменция (Mild Demented) и умеренная деменция (Moderate Demented).

Метрика оценки качества классификации Recall отражает долю правильно предсказанных положительных примеров среди всех истинных положительных и описывается по

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (11)$$

где TP (True Positives) – количество правильно предсказанных положительных примеров; FN (False Negatives) – количество неправильно предсказанных отрицательных примеров [17].

Рассмотрим распределение Recall по каждому классу в виде столбчатой диаграммы (рис. 2).




Рис. 2. Распределение Recall по каждому классу

Fig. 2. Recall distribution for each class

Метрика оценки качества классификации Specificity отражает насколько хорошо модель распознает здоровых пациентов и описывается по (12):

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}}, \quad (12)$$

где TN (True Negatives) – количество правильно предсказанных отрицательных примеров; FP (False Positives) – количество неправильно предсказанных положительных примеров.

Распределение Specificity по каждому классу в виде столбчатой диаграммы изображено ниже (рис. 3).

Метрика оценки качества классификации Precision отражает долю истинных положительных предсказаний среди всех случаев и описывается по (13):

$$\text{Precision} = \frac{TP}{TP+FP}. \quad (13)$$

Рассмотрим распределение Precision по каждому классу в виде столбчатой диаграммы (рис. 4).




Рис. 3. Распределение Specificity по каждому классу

Fig. 3. Distribution of Specificity for each class

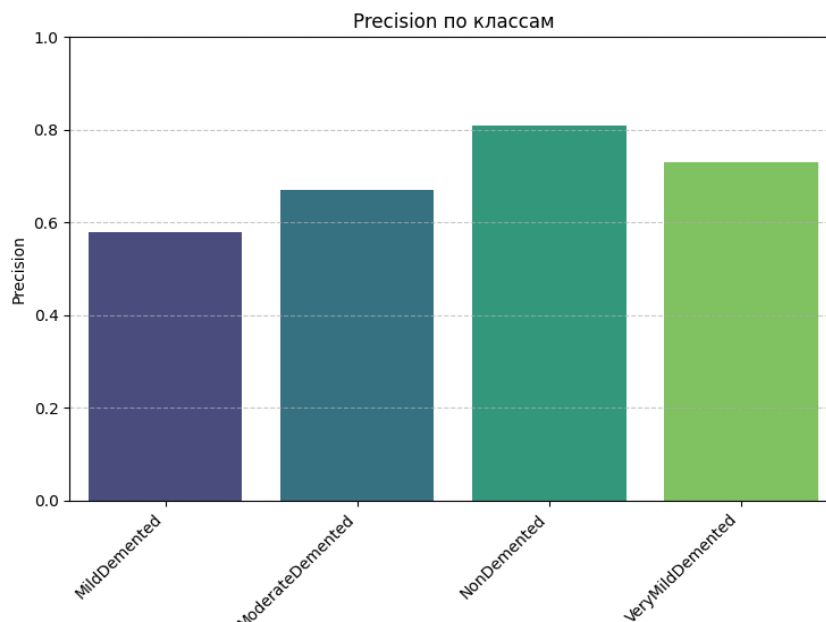


Рис. 4. Распределение Precision по каждому классу

Fig. 4. Distribution of Precision for each class

Метрика оценки качества классификации F1-мера является гармоническим средним между Precision и Recall и описывается

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (14)$$

Распределение F1-меры по каждому классу в виде столбчатой диаграммы изображено ниже (рис. 5).




Рис. 5. Распределение F1-меры по каждому классу

Fig. 5. Distribution of F1-measures for each class

Для решения задачи применения ROC-анализа для многоклассовой классификации был применен метод one-vs-all, заключающийся в создании бинар-

ных классификаторов для каждого класса [18]. Графики полученных ROC-кривых представлены ниже (рис. 6).

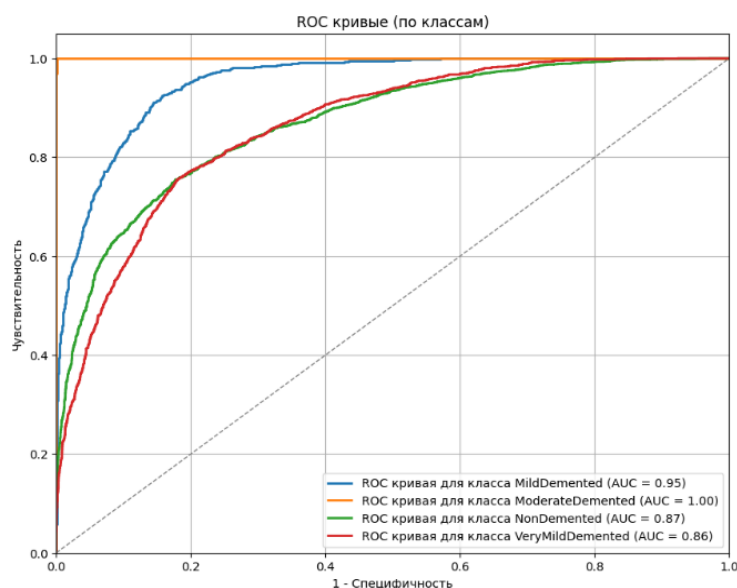


Рис. 6. Графики ROC-кривых

Fig. 6. ROC curve graphs

Проведенный анализ показал, что модель демонстрирует особенно высокую чувствительность к классу Moderate Demented – Recall и достигает значения 1,00. Это означает, что система не пропустила ни одного случая умеренной деменции в тестовой выборке. Более того, значение метрики Specificity для данного класса, также равное 1,00, свидетельствует о полном отсутствии ложноположительных срабатываний. Однако анализ других классов выявил определённые ограничения. В частности, значение Recall для класса Very Mild Demented составило 0,64, а для класса Non Demented – 0,76. Это указывает на то, что модель значительно хуже распознаёт ранние или незатронутые формы когнитивного состояния. Общий анализ ROC-кривых показывает, что модель обладает высокой дискриминационной способностью для большинства классов, особенно для Moderate Demented и Mild

Demented. Более низкие значения AUC для Non Demented и Very Mild Demented могут свидетельствовать о том, что для этих классов существует большая степень перекрытия признаков, что затрудняет их точную дифференциацию. Также это может быть обусловлено низкой выраженностью признаков на МРТ-снимках и частичной схожестью структурных изменений на ранних этапах заболевания.

В таблице 1 приведены значения метрики AUC-ROC, полученные авторами [19] в ходе вышеупомянутого исследования для четырех НМ на основе СНС (GoogLeNet, DenseNet-121, GoogLeNet на основе объединения признаков, DenseNet-121 на основе объединения признаков), а также результаты, полученные в ходе описанного в данной работе исследования для модифицированной архитектуры EfficientNetB3.

Таблица 1. Значения метрики AUC-ROC для [19] и модифицированной архитектуры EfficientNetB3

Table 1. AUC-ROC metric values for [19] and modified EfficientNetB3 architecture

Класс	НМ				
	GoogLeNet	DenseNet-121	GoogLeNet на основе объединения признаков	DenseNet-121 на основе объединения признаков	модифицированная архитектура EfficientNetB3
	AUC %				
Отсутствие признаков деменции (Non Demented)	97,25	96,84	98,25	98,10	87,00
Очень лёгкая деменция (Very Mild Demented)	94,69	95,79	96,67	97,54	86,00
Лёгкая деменция (Mild Demented)	92,51	91,49	97,52	97,95	95,00
Умеренная деменция (Moderate Demented)	85,72	89,12	84,56	94,64	100,00

Анализ этих значений показывает, что результаты модифицированной архитектуры EfficientNetB3, несмотря на их асимметричность, являются конкурентоспособными и выгодно отличаются от подходов, описанных в ряде современных исследований. В работах, где применяются базовые архитектуры НМ, такие как VGG-16 или ResNet-18, часто сообщается о проблеме снижения точности на миноритарных или сложных для дифференциации классах. Например, в исследовании [20] модель ResNet18, хотя и показала высокую общую точность, демонстрировала заметно более низкие показатели метрики Recall для ранних стадий заболевания, что указывает на трудности с идентификацией специфических паттернов.

Выводы

В данной работе проведена оценка эффективности НМ на основе модифицированной архитектуры EfficientNetB3 с применением трансферного глубокого обучения для дифференциальной диагностики стадий болезни Альцгеймера. Результаты, продемонстрированные модифицированной архитектурой EfficientNetB3, характеризуются выраженной асимметрией и указывают на узкоспециализированный характер данной модели. С одной стороны, НМ проявила себя как эффективный инструмент для диагностики стадии умеренной деменции, продемонстрировав максимально возможное значение AUC, равное 1,00. Этот факт свидетельствует о

способности детектировать и интерпретировать комплекс патологических изменений, характерных для данной выраженной стадии заболевания. С другой стороны, эффективность классификации для остальных классов («Отсутствие деменции», «Очень лёгкая деменция» и «Лёгкая деменция») оказалась существенно ниже не только в абсолютном выражении, но и по сравнению с альтернативными подходами, основанными на комбинации признаков. Значения AUC для классов «Отсутствие деменции» (0,87), «Очень лёгкая деменция» (0,86) и «Лёгкая деменция» (0,95) являются самыми низкими среди всех представленных в таблице 1 моделей, за исключением базовых версий GoogLeNet и DenseNet-121 для некоторых классов. Такая диспропорция позволяет предположить, что в процессе обучения или проектирования архитектура приобрела высокую специфичность к признакам, релевантным именно для умеренной деменции, потенциально в ущерб чувствительности к более ранним проявлениям нейродегенеративного процесса.

Таким образом, можно сделать вывод, что основная практическая ценность модификации архитектуры EfficientNetB3 может заключаться в ее использовании в составе гетерогенных ансамблей или каскадных системах диагностики для верификации конкретной стадии БА – умеренной деменции с целью повышения общей эффективности системы. Это указывает на перспективность дальнейших исследований в

области создания узкоспециализированных архитектур, способных решать конкретные подзадачи с высокой точностью, превосходящей универсальные, но менее сфокусированные подходы.

Список литературы

1. Особенности клинического течения нейродегенеративного заболевания головного мозга, обусловленного мутациями в гене нейрофасцита и сукцинатдегидрогеназы: клинический случай / Е. А. Ткачук, Т. А. Астахова, Л. В. Рычкова, О. В. Бугун // Медицинский совет. 2023. Т. 17, № 21. С. 122–127. <https://doi.org/10.21518/ms2023-414>
2. Bagetta G., Bano D., Scuteri D. Basic, Translational, and Clinical Research on Dementia // International Journal of Molecular Sciences. 2024. Vol. 25(13). P. 1–6. <https://doi.org/10.3390/ijms25136861>
3. Применение современных классификационных систем для комплексной диагностики болезни Альцгеймера / Я. А. Зоркина, И. О. Морозова, О. В. Абрамова [и др.] // Журнал неврологии и психиатрии им. С. С. Корсакова. 2024. Т. 124, № 1. С. 121–127. <https://doi.org/10.17116/jnevro2024124011121>
4. Возможности и перспективы метода магнитно-резонансной морфометрии в диагностике деменций / И. К. Терновых, С. В. Воробьев, С. Н. Янишевский [и др.] // Медицинский совет. 2024. Т. 18, № 12. С. 22–30. <https://doi.org/10.21518/ms2024-289>
5. Брежнев А. В., Томакова Р. А., Черных Е. В. Информационная система для прогнозирования рецидивов инфаркта миокарда, реализованная как мобильное приложение // Информационное общество. 2023. № 1. С. 116–126. https://doi.org/10.52605/16059921_2023_01_116
6. Томакова Р. А., Дзюбин И. А., Брежнев А. В. Метод и алгоритм обучения сверточной нейронной сети, предназначенной для интеллектуальной системы распознавания меланомы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 1. С. 65–83. <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>
7. Анализ эффективности применения архитектуры U-net для классификации и сегментации глиомы на МРТ-снимках / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 3. С. 104–120. <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>
8. Patel V. AI-Driven Alzheimer's Detection Performance Analysis of Pretrained CNN Models on MRI Data // International Journal for Research in Applied Science and Engineering Technology. 2025. Vol. 13. P. 776–784. <https://doi.org/10.22214/ijraset.2025.68354>

9. Diagnosis of Alzheimer's Disease Using CNN on MRI Data / P. Agarwal, V. Jagawat, B. Jathiswar, M. Poonkodi // *Advances in Science and Technology*. 2023. Vol. 124. P. 277–284. <https://doi.org/10.4028/p-z04kn>
10. Naidu G., Zuva T., Sibanda E. M. A review of evaluation metrics in machine learning algorithms // *Artificial Intelligence Application in Networks and Systems: Proceedings of 12th Computer Science On-line Conference 2023*. Cham: Springer, 2023.
11. Knapieńska Z., Mulawka J. Patient-Tailored Dementia Diagnosis with CNN-Based Brain MRI Classification // *Applied Sciences*. 2025. Vol. 15. <https://doi.org/10.3390/app15094652>
12. Азарнова Т. В., Поздняков Д. А. Применение методов глубокого обучения для классификации стадии Альцгеймера на основе МРТ головного мозга // *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*. 2024. № 1. С. 94–103. <https://doi.org/10.17308/sait/1995-5499/2024/1/94-103>
13. Overview of ADNI MRI / C. R. Jack, A. Arani, B. J. Borowski [et al.] // *Alzheimer's Dement.* 2024. Vol. 20. P. 7350–7360. <https://doi.org/10.1002/alz.14166>
14. The class imbalance problem in deep learning / K. Ghosh, C. Bellinger, R. Corizzo [et al.] // *Mach Learn.* 2024. Vol. 113. P. 4845–4901. <https://doi.org/10.1007/s10994-022-06268-8>
15. Image Augmentation Techniques for Mammogram Analysis / P. Oza, P. Sharma, S. Patel [et al.] // *J. Imaging*. 2022. Vol. 8(141). <https://doi.org/10.3390/jimaging8050141>
16. A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope / A. W. Salehi, S. Khan, G. Gupta [et al.] // *Sustainability*. 2023. N 15 (7). P. 5930. <https://doi.org/10.3390/su15075930>
17. Метод контроля доступа и мониторинга соблюдения техники безопасности на энергетических хозяйствах предприятий на основе конвейерной нейросетевой модели / А. В. Киселев, Н. С. Брусенцев, Е. А. Кулешова, Д. А. Ермаков // *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2024. Т. 14, № 4. С. 28–46. <https://doi.org/10.21869/2223-1536-2024-14-4-28-46>
18. Метод анализа оцифрованных рентгеновских снимков грудной клетки для дифференциальной диагностики инфекционных заболеваний дыхательной системы / И. О. Мишин, М. О. Таныгин, А. В. Киселев [и др.] // *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*. 2024. № 4. С. 143–155. <https://doi.org/10.17308/sait/1995-5499/2024/4/143-155>
19. Automatic Analysis of MRI Images for Early Prediction of Alzheimer's Disease Stages Based on Hybrid Features of CNN and Handcrafted Features / A. Khalid, E. M. Senan,

K. Al-Wagih [et al.] // *Diagnostics (Basel)*. 2023. Vol. 13 (9). P. 1654. <https://doi.org/10.3390/diagnostics13091654>

20. Analysis of Features of Alzheimer's Disease: Detection of Early Stage from Functional Brain Changes in Magnetic Resonance Images Using a Finetuned ResNet18 Network / M. Odusami, R. Maskeliūnas, R. Damaševičius, T. Krilavičius // *Diagnostics (Basel)*. 2021. Vol. 11 (6). P. 1071. <https://doi.org/10.3390/diagnostics11061071>

References

1. Tkachuk E.A., Astakhova T.A., Rychkova L.V., Bugun O.V. Features of the clinical course of neurodegenerative brain disease caused by mutations in the neurofascyte and succinate dehydrogenase gene: a clinical case. *Meditinskii sovet = Medical Advice*. 2023;17(21):122–127. (In Russ.) <https://doi.org/10.21518/ms2023-414>

2. Bagetta G., Bano D., Scuteri D. Basic, Translational, and Clinical Research on Dementia. *International Journal of Molecular Sciences*. 2024;25(13):1–6. <https://doi.org/10.3390/ijms25136861>

3. Zorkina Ya.A., Morozova I.O., Abramova O.V., et al. Application of modern classification systems for the complex diagnosis of Alzheimer's disease. *Zhurnal nevrologii i psikiatrii im. S. S. Korsakova = Journal of Neurology and Psychiatry named after S. S. Korsakov*. 2024;124(1):121–127. (In Russ.) <https://doi.org/10.17116/jnevro2024124011121>

4. Ternovykh I.K., Vorobyov S.V., Yanishevsky S.N., et al. Possibilities and prospects of the magnetic resonance morphometry method in the diagnosis of dementia. *Meditinskii sovet = Medical Council*. 2024;18(12):22–30. (In Russ.) <https://doi.org/10.21518/ms2024-289>

5. Brezhnev A.V., Tomakova R.A., Chernykh E.V. Information system for predicting recurrence of myocardial infarction, implemented as a mobile application. *Informatsionnoe obshchestvo = Information Society*. 2023;(1):116–126. (In Russ.) https://doi.org/10.52605/16059921_2023_01_116

6. Tomakova R.A., Dzyubin I.A., Brezhnev A.V. A method and algorithm for learning a convolutional neural network designed for an intelligent melanoma recognition system. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2022;12(1):65–83. (In Russ.) <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>

7. Kiselev A.V., Kuleshova E.A., Tanygin M.O., et al. An analysis of the effectiveness of the U-net architecture for classification and segmentation of glioma on MRI images. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State*

University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2024;14(3):104–120. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>

8. Patel V. AI-Driven Alzheimer's Detection Performance Analysis of Pretrained CNN Models on MRI Data. *International Journal for Research in Applied Science and Engineering Technology*. 2025;13:776–784. <https://doi.org/10.22214/ijraset.2025.68354>

9. Agarwal P., Jaga-wat V., Jathiswar B., Poonkodi M. Diagnosis of Alzheimer's Disease Using CNN on MRI Data. *Advances in Science and Technology*. 2023;124:277–284. <https://doi.org/10.4028/p-z04kn>

10. Naidu G., Zuva T., Sibanda E. M. A review of evaluation metrics in machine learning algorithms. In: *Artificial Intelligence Application in Networks and Systems: Pro-ceedings of 12th Computer Science On-line Conference 2023*. Cham: Springer; 2023.

11. Knapieńska Z., Mulawka J. Patient-Tailored Dementia Diagnosis with CNN-Based Brain MRI Classification. *Applied Sciences*. 2025;15. <https://doi.org/10.3390/app15094652>

12. Azarnova T.V., Pozdnyakov D.A. Application of deep learning methods for classification of Alzheimer's stage based on MRI of the brain. *Vestnik Voronezhskogo gosudarstvennogo universiteta. Seriya: Sistemnyi analiz i informatsionnye tekhnologii = Bulletin of Voronezh State University. Series: System analysis and information technologies*. 2024;(1):94–103. (In Russ.) <https://doi.org/10.17308/sait/1995-5499/2024/1/94-103>

13. Jack C.R., Arani A., Borowski B.J., et al. Overview of ADNI MRI. *Alzheimer's Dementia*. 2024;20:7350–7360. <https://doi.org/10.1002/alz.14166>

14. Ghosh K., Bellinger C., Corizzo R., et al. The class imbalance problem in deep learning. *Mach Learn*. 2024;113:4845–4901. <https://doi.org/10.1007/s10994-022-06268-8>

15. Oza P., Sharma P., Patel S., et al. Image Augmentation Techniques for Mammogram Analysis. *J. Imaging*. 2022;8(141). <https://doi.org/10.3390/jimaging8050141>

16. Salehi A.W., Khan S., Gupta G., et al. A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope. *Sustainability*. 2023;(15):5930. <https://doi.org/10.3390/su15075930>

17. Kiselev A.V., Brusentsev N.S., Kuleshova E.A., Ermakov D.A. A method of access control and safety monitoring at energy facilities of enterprises based on a conveyor neural network model. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(4):28–46. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-4-28-46>

18. Mishin I.O., Tanygin M.O., Kiselyov A.V., et al. Method of analysis of digitized chest X-rays for differential diagnosis of infectious diseases of the respiratory system.

Vestnik Voronezhskogo gosudarstvennogo universiteta. Seriya: Sistemnyi analiz i informatsionnye tekhnologii = Bulletin of Voronezh State University. Series: System analysis and Information technologies. 2024;(4):143–155. (In Russ.) <https://doi.org/10.17308/sait/1995-5499/2024/4/143-155>

19. Khalid A., Senan E.M., Al-Wagih K., et al. Automatic Analysis of MRI Images for Early Prediction of Alzheimer's Disease Stages Based on Hybrid Features of CNN and Hand-crafted Features. *Diagnostics (Basel)*. 2023;13(9):1654. <https://doi.org/10.3390/diagnostics13091654>

20. Odusami M., Maskeliūnas R., Damaševičius R., Krilavičius T. Analysis of Features of Alzheimer's Disease: Detection of Early Stage from Functional Brain Changes in Magnetic Resonance Images Using a Finetuned ResNet18 Network. *Diagnostics (Basel)*. 2021;11(6):1071. <https://doi.org/10.3390/diagnostics11061071>

Информация об авторах / Information about the Authors

Киселев Алексей Викторович, кандидат технических наук, доцент, доцент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281

Alexey V. Kiselev, Candidate of Sciences (Engineering), Associate Professor, Associate Professor of the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation, e-mail: kiselevalexey1990@gmail.com, ORCID: 0000-0001-7228-0281

Кулешова Елена Александровна, кандидат технических наук, доцент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Elena A. Kuleshova, Candidate of Sciences (Engineering), Associate Professor, Associate Professor of the Department of Information Security, Southwest State University, Kursk, Russian Federation, e-mail: lena.kuleshova.94@mail.ru, ORCID: 0000-0002-8270-564X

Таныгин Максим Олегович, доктор технических наук, доцент, профессор кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

Maxim O. Tanygin, Doctor of Sciences (Engineering), Associate Professor, Professor of the Department of Information Security, Southwest State University, Kursk, Russian Federation, e-mail: tanygin@yandex.ru, ORCID: 0000-0002-4099-1414

Свинухов Павел Михайлович, аспирант кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация
e-mail: p.8848@yandex.ru,
ORCID: 0009-0005-2017-7107

Pavel R. Svinuhov, Postgraduate of the Department of Information Security, Southwest State University, Kursk, Russian Federation,
e-mail: p.8848@yandex.ru,
ORCID: 0009-0005-2017-7107

Халин Игорь Алексеевич, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: yur-khalin@yandex.ru,
ORCID: 0009-0004-1205-2139

Igor A. Khalin, Postgraduate of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: yur-khalin@yandex.ru,
ORCID: 0009-0004-1205-2139