

УДК 004.853

DOI: 10.35330/1991-6639-2025-27-2-103-112

EDN: PFILQX

Научная статья

Модели и методы глубокого обучения в задачах распознавания и классификации медицинских изображений

И. А. Пшенокова^{✉1,2}, М. Р. Киясов²

¹Институт информатики и проблем регионального управления – филиал Кабардино-Балкарского научного центра Российской академии наук
360000, Россия, г. Нальчик, ул. И. Арманд, 37-а

²Кабардино-Балкарский государственный университет имени Х. М. Бербекова
360004, Россия, г. Нальчик, ул. Чернышевского, 173

Аннотация. В работе проведено исследование и анализ моделей и методов глубокого обучения в задачах распознавания и классификации изображений опухолей мозга. Для сравнения эффективности наиболее актуальных и доступных моделей на основе сверточных нейронных сетей были выбраны модели VGG19, Xception и ResNet152. Наилучшие результаты показала модель Xception. Целью данной работы являются оптимизация и обучение выбранной модели с помощью различных методов для повышения точности диагностики опухолей головного мозга человека. Предложена и реализована стратегия для улучшения этой модели с использованием методов переноса обучения и аугментации данных. Из проведенных тестов следует, что улучшенная модель демонстрирует более высокую точность и устойчивость к различным видам искажений данных, что делает ее более эффективной для задач распознавания и классификации изображений.

Ключевые слова: методы распознавания изображений, методы глубокого обучения, сверточные нейронные сети, методы переноса обучения

Поступила 14.03.2025, одобрена после рецензирования 07.04.2025, принята к публикации 09.04.2025

Для цитирования. Пшенокова И. А., Киясов М. Р. Модели и методы глубокого обучения в задачах распознавания и классификации медицинских изображений // Известия Кабардино-Балкарского научного центра РАН. 2025. Т. 27. № 2. С. 103–112. DOI: 10.35330/1991-6639-2025-27-2-103-112

MSC: 68T42

Original article

Models and methods of deep learning in medical image recognition and classification tasks

I.A. Pshenokova^{✉1,2}, M.R. Kiyasov²

¹Institute of Computer Science and Problems of Regional Management – branch of Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences
360000, Russia, Nalchik, 37-a I. Armand street

²Kabardino-Balkarian State University named after Kh.M. Berbekov
360004, Russia, Nalchik, 173 Chernyshevsky street

Abstract. The paper presents a study and analysis of deep learning models and methods in the problems of recognition and classification of brain tumor images. To compare the effectiveness of the most relevant and available models based on convolutional neural networks, the VGG19, Xception,

and ResNet152 models were selected. The Xception model showed the best results. The purpose of this work is to optimize and train the selected model using various methods to improve the accuracy of diagnosing human brain tumors. A strategy for improving this model using transfer learning and data augmentation methods is proposed and implemented. The tests show that the improved model demonstrates higher accuracy and resistance to various types of data distortions, which makes it more effective for image recognition and classification tasks.

Keywords: image recognition methods, deep learning methods, convolutional neural networks, transfer learning methods

Submitted 14.03.2025,

approved after reviewing 07.04.2025,

accepted for publication 09.04.2025

For citation. Pshenokova I.A., Kiyasov M.R. Models and methods of deep learning in medical image recognition and classification tasks. *News of the Kabardino-Balkarian Scientific Center of RAS*. 2025. Vol. 27. No. 2. Pp. 103–112. DOI: 10.35330/1991-6639-2025-27-2-103-112

ВВЕДЕНИЕ

Технологии распознавания и классификации изображений являются неотъемлемой частью многих отраслей экономики, таких как медицина, автомобилестроение, системы безопасности и развлечения. Методы распознавания позволяют автоматизировать такие процессы, как извлечение информации, распознавание объектов и лиц, сжатие изображений, медицинская визуализация, а также повышать их эффективность.

Распознавание изображений – это область компьютерного зрения и машинного обучения, сосредоточенная на идентификации и классификации объектов в изображениях и видео. Поскольку объем визуальной информации растет с каждым годом, необходимо разрабатывать новые или улучшать имеющиеся методы их обработки.

Традиционные методы распознавания изображений включают в себя различные алгоритмы и техники, которые использовались до широкого распространения глубокого обучения. Их можно подразделить на несколько категорий: методы, основанные на извлечении признаков (SIFT, SURF, HOG и LBP), методы классификации (метод опорных векторов, k-means и деревья решений) и классические алгоритмы (гистограммное выравнивание, фильтрация и сегментация). Однако так как эти методы основываются на ручном анализе, они становятся все менее эффективными в условиях больших данных. Актуальность данной работы обусловлена растущими требованиями к автоматизации анализа визуальной информации и необходимостью разработки более современных, точных и устойчивых моделей, способных работать в условиях реального времени и с разнообразными типами данных.

Глубокое обучение и нейронные сети произвели революцию в области распознавания изображений, обеспечивая значительные улучшения в точности и эффективности по сравнению с классическими методами [1]. Основные методы и архитектуры, используемые в этой области, приведены на рисунке 1.



Рис. 1. Методы глубокого обучения в распознавании изображений

Fig. 1. Deep learning methods in image recognition

Как видно из рисунка, существует множество подходов к распознаванию и классификации визуальной информации, однако основными являются сверточные нейронные сети (CNN), которые эффективно обрабатывают изображения благодаря своей архитектуре (рис. 2), позволяющей выявлять пространственные и временные зависимости [2].

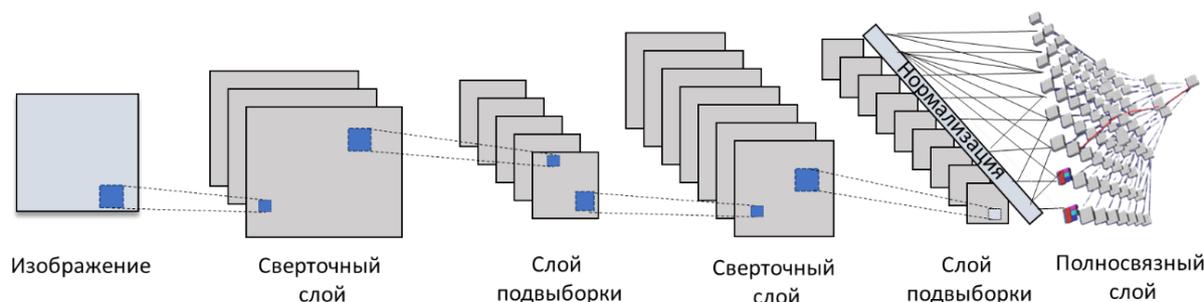


Рис. 2. Архитектура сверточной нейронной сети

Fig. 2. Architecture of a convolutional neural network

Сверточный слой является основным элементом и выполняет свертку входных данных, выделяя важные характеристики изображения на различных уровнях абстракции, такие как края, текстуры или формы. Далее данные поступают на слой подвыборки, который за счет сохранения наиболее значимых признаков уменьшает размерность выходных данных, сокращая при этом вычислительные затраты. Выходы слоя подвыборки нормализуются для каждого пакета данных, что позволяет уменьшить влияние изменений в распределении данных и способствует эффективному и быстрому обучению модели. В завершающей части сети данные передаются в полносвязный слой, где каждый нейрон соединен со всеми нейронами предыдущего слоя. Этот слой отвечает за окончательную классификацию или регрессионный анализ на основе извлеченных признаков.

СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ АНАЛИЗА МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ

Сверточная нейронная сеть является одним из наиболее широко используемых методов в области медицинских изображений, особенно в области анализа медицинских изображений.

Идентификация изображений была одной из первых областей анализа медицинской визуализации. Качественный и количественный анализ изображений, выполненный методами глубокого обучения, играет незаменимую роль в медицинской диагностике для клинической терапии [3, 4]. Кроме того, использование машинного обучения для сегментации медицинских изображений может эффективно помочь врачам подтвердить размер пораженных опухолей, количественно оценить эффект до и после лечения, снизить нагрузку на врачей [5].

Преимущество глубокого обучения, особенно глубоких сверточных сетей [6], заключается в том, что функция ручного сбора данных может быть заменена эффективными алгоритмами неконтролируемого или полуконтролируемого обучения признаков и иерархического извлечения признаков. Так, в работах [7, 8, 9] представлены преимущества сверточных нейронных сетей при диагностике заболеваний на основе классификации и сегментации МРТ- и КТ-изображений головного мозга и рентгеновских изображений легких, в частности, задачи, в которых была изучена диагностическая и прикладная ценность модели глубокого обучения. Методы глубокого обучения обучают модель слиянию с хорошей способностью к обобщению на основе большого объема данных, что может сделать процесс слияния более надежным и преодолеть недостатки ручного выбора функций, такие как дороговизна, трудоемкость и подверженность человеческим ошибкам.

Разница между сверточной нейронной сетью (СНС) и традиционными полносвязными нейронными сетями состоит в способности захватывать корреляционные пространственно-временные зависимости в данных, что позволяет эффективно обрабатывать изображения и выделять локальные особенности [10].

Существует множество моделей сверточных нейронных сетей, широко используемых для решения задач распознавания и классификации медицинских изображений. Так, в [11] представлен алгоритм классификации МРТ мелких сосудов головного мозга с использованием сверточной нейронной сети. В [12] авторы разработали многопоточную глубокую сверточную нейронную сеть для классификации стабильных легких когнитивных нарушений для ранней диагностики болезни Альцгеймера.

Авторы в [13] представили новую модель, которая объединила глубокие сверточные сети с байесовским алгоритмом для прогнозирования и классификации опухолей головного мозга для изображений МРТ.

Интеграция модулей внимания со сверточными сетями представлена в [14] для неиерархического анализа медицинских изображений (задачи оценки деменции, классификация расстройств мозга и классификация опухолей мозга).

В работе [15] разработали новую остаточную нейронную сеть для классификации инсульта. Авторами проведена количественная оценка предложенного метода в трех различных слоях.

В [16] проведены компьютерные исследования эффективности применения методов переноса глубокого обучения для решения задачи распознавания опухолей головного мозга человека на основе его МРТ-снимков. Авторами предложены различные стратегии глубокого обучения и тонкой настройки моделей на основе глубоких сверточных сетей.

В настоящей работе мы рассмотрим наиболее актуальные и доступные СНС, в частности, VGGNet, Xception, и ResNet [17].

VGGNet известна своей глубиной, достигающей до 19 слоев, и использованием сверточных слоев с небольшими фильтрами размером 3×3 . Архитектура акцентирует внимание на простоте и повторяемости структуры, что делает ее удобной для понимания и реализации [18]. Однако из-за своей глубокой структуры VGGNet имеет высокую вероятность переобучения и может демонстрировать длительное время предсказания.

Xception является улучшенной версией Inception и использует глубокие сепарабельные свертки. Эти свертки разбивают стандартную свертку на две части: сначала применяется свертка по глубине (с ядром 1×1), а затем свертка по пространству (с ядром 3×3). Это позволяет значительно уменьшить количество параметров и вычислительные затраты.

ResNet ввела концепцию остаточных соединений, что позволило создавать очень глубокие сети без проблем затухания градиентов [19]. Однако с увеличением количества слоев также возрастает сложность подбора гиперпараметров и требуются значительные вычислительные ресурсы и память для глубоких моделей.

Сравним эффективность этих моделей. Для сравнения были выбраны следующие версии ранее описанных моделей: VGG19, Xception и ResNet152.

Моделям предоставляются изображения, на которых изображены различные виды опухолей мозга, а также изображения, не содержащие опухолей. Эти данные организованы в папки, каждая из которых содержит множество изображений в формате JPG, соответствующих определенным классам: «glioma», «meningioma», «pituitary» и «notumor». Поскольку выбранные модели доступны, достаточно просто импортировать их через соответствующие библиотеки и обучить на тренировочных данных для последующего тестирования. Обучение и тестирование проводились с использованием одинаковых названий папок, но с разным содержимым, которые были взяты с сайта Kaggle [20]. В качестве платформы использовалась Google Colab, так как обучение моделей потребует значительных ресурсов.

Результаты тестирования моделей по классам представлены в таблице 1.

Таблица 1. Результаты тестирования моделей VGG19, Xception, ResNet152 по классам

Table 1. Test results of VGG19, Xception, ResNet152 models by classes

Модель	Общее количество изображений	Количество обработанных изображений класса	Процент обнаружений класса
<i>Класс «glioma»</i>			
VGG19	300	157	52,33%
Xception	300	232	77,33%
ResNet152	300	134	44,67%
<i>Класс «meningioma»</i>			
VGG19	306	9	2,94%
Xception	306	180	58,82%
ResNet152	306	115	44,67%
<i>Класс «pituitary»</i>			
VGG19	300	260	86,67%
Xception	300	277	92,33%
ResNet152	300	180	60%
<i>Класс «notumor»</i>			
VGG19	405	369	91,11%
Xception	405	389	96,05%
ResNet152	405	263	64,94%

Из таблицы видно, что модель VGG19 показала средний результат на папке «glioma», но с папкой «meningioma» справилась очень плохо. Однако смогла правильно классифицировать почти все изображения из папки «notumor». С последней папкой модель справилась немного хуже, чем с предыдущей, правильно распознав 260 из 300 фотографий. Модель VGG19 показала наилучший результат на папке «notumor», достигнув 91,11 % точности обнаружения, в то время как наихудший результат был зафиксирован на папке «meningioma» с процентом обнаружения 2,94 %.

Модель Xception показала хороший результат на папке «glioma». На папке «meningioma» модель показала средний результат, правильно распознав почти 60 % изображений. С папкой «notumor» модель справилась почти идеально и показала отличный результат с последней папкой. Модель Xception показала наилучший результат на папке «notumor», достигнув 92,33 % правильного распознавания. Наихудший результат был получен в папке «meningioma» с процентом правильного распознавания 58,82 %.

Модель ResNet152 смогла правильно обнаружить чуть меньше половины изображений из папки «glioma», с папкой «meningioma» модель справилась немного хуже, на папке «notumor» был получен результат немного выше среднего – 64,94 %, и с последней папкой модель справилась немного хуже, чем с предыдущей, распознав 180 изображений из 300. Наилучший результат модель ResNet152 показала с папкой «notumor», достигнув 64,94 % обнаружения, в то время как наихудший результат был зафиксирован с папкой «meningioma» – 37,58 %.

Таким образом, за счет разбивки стандартной свертки на две части по глубине и пространству и значительного уменьшения количества обрабатываемых параметров среди всех моделей лучший процент обнаружений класса показала модель Xception.

Целью данной работы являются оптимизация и обучение выбранной модели с помощью различных методов для повышения точности диагностики опухолей головного мозга человека.

УЛУЧШЕНИЕ МОДЕЛИ РАСПОЗНАВАНИЯ И КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ

Используем метод переноса обучения в распознавании изображений. В качестве базовой модели классификации будем использовать предобученную модель Xception, в которой заморожены первые 70 слоев. Под операцией заморозки понимается процедура фиксации значений весов сверточных слоев таким образом, что они не будут обновляться во время обучения модели, что позволяет модели лучше адаптироваться к отобранным данным, при этом учитывая информацию, которая была использована на этапе обучения предобученной модели. Остальные слои остаются доступны для обучения на отобранных данных. Далее добавляются новые слои с функцией активации «softmax» с указанием необходимого числа классов, специально предназначенные для обработки изображений на основе имеющихся данных.

Затем модель компилируется с использованием оптимизатора Adam, задается функция потерь categorical_crossentropy и определяется метрика accuracy для оценки точности.

Затем для аугментации данных используем ImageDataGenerator. В этом объекте задаются различные параметры аугментации, такие как изменение масштаба, вращение, сдвиги по ширине и высоте, сдвиг по углу, масштабирование и горизонтальное отражение изображений. Эти методы помогают модели лучше обрабатывать изображения и улучшают ее способность к обобщению. Далее указываем путь к папке, содержащей данные для обучения, задаем размеры изображений для модели, размер батча для итераций обучения и класс данных «categorical». Чтобы избежать переобучения, используем метод обратного вызова EarlyStopping с соответствующими параметрами.

После завершения настройки сети и работы с программой запускается процесс обучения. Обучение построенной модели проводилось с функцией потерь «categorical_crossentropy» и

показателем точности accuracy. Начальная скорость обучения была установлена равной $1e-4$, модель обучалась в течение 32 эпох с параметром batch size = 32. По окончании обучения получается следующий результат (рис. 3).

```
Found 5712 images belonging to 4 classes.
179/179 ————— 6360s 35s/step - accuracy: 0.8324 - loss: 0.4120
WARNING:absl:You are saving your model as an HDF5 file via `model.save()` or `
```

Рис. 3. Результат обучения модели

Fig. 3. Model training result

ТЕСТИРОВАНИЕ ПОЛУЧЕННОЙ МОДЕЛИ И АНАЛИЗ РЕЗУЛЬТАТОВ

После завершения обучения модель была протестирована на тренировочных данных. Сравнительные результаты тестирования приведены в таблице 2.

Таблица 2. Результаты тестирования предобученной модели Xception и ее улучшенной версии

Table 2. Test results of the pre-trained Xception model and its improved version

Модель	Общее количество изображений	Количество обработанных изображений класса	Процент обнаружений класса
<i>Класс «glioma»</i>			
Xception	300	232	77,33%
Улучшенная модель	300	298	99,33%
<i>Класс «meningioma»</i>			
Xception	306	180	58,82%
Улучшенная модель	306	234	76,47%
<i>Класс «pituitary»</i>			
Xception	300	277	92,33%
Улучшенная модель	300	292	97,33%
<i>Класс «notumor»</i>			
Xception	405	389	96,05%
Улучшенная модель	405	405	100%

Из проведенных тестов предобученной модели Xception и ее улучшенной версии следует, что улучшенная модель демонстрирует более высокую точность и устойчивость к различным видам искажений данных, что делает ее более эффективной для задач классификации изображений.

ЗАКЛЮЧЕНИЕ

В рамках работы были проведены исследование и анализ моделей распознавания и классификации изображений в области медицины. После сравнения наиболее актуальных и доступных моделей на основе сверточных нейронных сетей была выбрана модель Xception, показавшая наилучшие результаты. Эта модель была улучшена с использованием методов переноса обучения и аугментации данных для повышения точности диагностики опухолей головного мозга человека. Из проведенных тестов следует, что улучшенная модель демонстрирует более высокую точность и устойчивость к различным видам искажений данных, что делает ее более эффективной для задач распознавания и классификации изображений.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Bishop C.M. Pattern recognition and machine learning (Information Science and Statistics). Springer. New York. 2007. ISBN: 0-387-31073-8
2. Li Z. et al. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*. 2021. Vol. 33. No. 12. Pp. 6999–7019. DOI: 10.1109/TNNLS.2021.3084827
3. Byra M. et al. Breast mass classification in sonography with transfer learning using a deep convolutional neural network and color conversion. *Medical physics*. 2019. Vol. 46. No. 2. Pp. 746–755. DOI: 10.1002/mp.13361
4. Horiuchi Y. et al. Convolutional neural network for differentiating gastric cancer from gastritis using magnified endoscopy with narrow band imaging. *Digestive diseases and sciences*. 2020. Vol. 65. Pp. 1355–1363. DOI: 10.1007/s10620-019-05862-6
5. Wang J. et al. Integral real-time locomotion mode recognition based on GA-CNN for lower limb exoskeleton. *Journal of Bionic Engineering*. 2022. Vol. 19. No. 5. Pp. 1359–1373. DOI: 10.1007/s42235-022-00230-z
6. Bhandari D., Paul S., Narayan A. Deep neural networks for multimodal data fusion and affect recognition. *International Journal of Artificial Intelligence and Soft Computing*. 2020. Vol. 7. No. 2. Pp. 130–145. DOI: 10.1504/IJAISC.2020.113475
7. Srivastava A., Singh A., Tiwari A. K. An efficient hybrid approach for the prediction of epilepsy using CNN with LSTM. *International Journal of Artificial Intelligence and Soft Computing*. 2022. Vol. 7. No. 3. Pp. 179–193. DOI: 10.1504/IJAISC.2022.126336
8. Khan H.A. et al. Brain tumor classification in MRI image using convolutional neural network. *Mathematical Biosciences and Engineering*. 2021. Vol. 17. No. 5. Pp. 6203–6216. DOI: 10.3934/mbe.2020328
9. Houssein E.H. et al. Hybrid quantum-classical convolutional neural network model for COVID-19 prediction using chest X-ray images. *Journal of Computational Design and Engineering*. 2022. Vol. 9. No. 2. Pp. 343–363. DOI: 10.1093/jcde/qwac003
10. Раскопина А. С., Боженко В. В., Татарникова Т. М. Использование глубокого обучения при диагностировании пневмонии по рентгеновским снимкам. *Известия высших учебных заведений. Приборостроение*. 2024. Т. 67. № 4. С. 315–320. DOI: 10.17586/0021-3454-2024-67-4-315-320
- Raskopina A.S., Bozhenko V.V., Tatarnikova T.M. Using deep learning in diagnosing pneumonia from X-ray images. *Izvestiya vysshikh uchebnykh zavedeniy. Priborostroyeniye* [News of higher educational institutions. Instrument engineering]. 2024. Vol. 67. No. 4. Pp. 315–320. DOI: 10.17586/0021-3454-2024-67-4-315-320. (In Russian)
11. Wan C. et al. Research on classification algorithm of cerebral small vessel disease based on convolutional neural network. *Journal of Intelligent & Fuzzy Systems*. 2023. Vol. 44. No. 2. Pp. 3107–3114.
12. Ashtari-Majlan M., Seifi A., Dehshibi M.M. A multi-stream convolutional neural network for classification of progressive MCI in Alzheimer’s disease using structural MRI images. *IEEE Journal of Biomedical and Health Informatics*. 2022. Vol. 26. No. 8. Pp. 3918–3926. DOI: 10.1109/JBHI.2022.3155705
13. Ekong F. et al. Bayesian depth-wise convolutional neural network design for brain tumor MRI classification. *Diagnostics*. 2022. Vol. 12. No. 7. P. 1657. DOI: 10.3390/diagnostics12071657
14. Apostolopoulos I.D., Aznaouridis S., Tzani M. An attention-based deep convolutional neural network for brain tumor and disorder classification and grading in magnetic resonance imaging. *Information*. 2023. Vol. 14. No. 3. P. 174. DOI: 10.3390/info14030174

15. Shi Y. et al. Residual convolutional neural network-based stroke classification with electrical impedance tomography. *IEEE Transactions on Instrumentation and Measurement*. 2022. Vol. 71. Pp. 1–11. DOI: 10.1109/TIM.2022.3165786

16. Щетинин Е. Ю., Севастьянов Л. А. О методах переноса глубокого обучения в задачах классификации биомедицинских изображений // Информатика и ее применения. 2021. Т. 15. № 4. С. 59–64. DOI: 10.14357/19922264210408. EDN: YQXVAA

Shchetinin E.Yu., Sevastyanov L.A. On deep learning transfer methods in biomedical image classification problems. *Informatika i yeyo primeneniya* [Computer Science and Its Applications]. 2021. Vol. 15. No. 4. Pp. 59–64. DOI: 10.14357/19922264210408. EDN: YQXVAA (In Russian)

17. Щукина Н. А. Нейросетевые модели в задаче классификации медицинских изображений // Моделирование, оптимизация и информационные технологии. 2021. Т. 9. № 4(35). DOI: 10.26102/2310-6018/2021.35.4.022. EDN: MXPABV

Shchukina N.A. Neural network models in the problem of classification of medical images. *Modelirovaniye, optimizatsiya i informatsionnyye tekhnologii* [Modeling, Optimization and Information Technology]. 2021. Vol. 9. No. 4(35). DOI: 10.26102/2310-6018/2021.35.4.022. EDN: MXPABV. (In Russian)

18. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. 2014. DOI: 10.48550/arXiv.1409.1556

19. Khan A. et al. A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*. 2020. Vol. 53. Pp. 5455–5516.

20. Набор данных МРТ опухоли головного мозга [Электронный ресурс]. URL: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>

Nabor dannykh MRT opukholi golovnogo mozga [Brain tumor MRI dataset]. [Electronic resource]. URL: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>. (accessed 10.03.2025)

Финансирование. Исследование проведено без спонсорской поддержки.

Funding. The study was performed without external funding.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Информация об авторах

Пшенокова Инна Ауесовна, канд. физ.-мат. наук, зав. лаб. «Интеллектуальные среды обитания», Институт информатики и проблем регионального управления – филиал Кабардино-Балкарского научного центра РАН;

360000, Россия, г. Нальчик, ул. И. Арманд, 37-а;

доцент кафедры «Компьютерные технологии и информационная безопасность», Кабардино-Балкарский государственный университет имени Х. М. Бербекова;

360004, Россия, г. Нальчик, ул. Чернышевского, 173;

pshenokova_inna@mail.ru, ORCID: <https://orcid.org/0000-0003-3394-7682>, SPIN-код: 3535-2963

Киясов Мурат Русланович, студент 4-го курса направления «Информатика и вычислительная техника», Кабардино-Балкарский государственный университет имени Х. М. Бербекова;

360004, Россия, г. Нальчик, ул. Чернышевского, 173;

murat7450@mail.ru

Information about the authors

Inna A. Pshenokova, Candidate of Physical and Mathematical Sciences, Head of the Laboratory of Intelligent Living Environments, Institute of Computer Science and Problems of Regional Management – branch of Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences;

360000, Russia, Nalchik, 37-a I. Armand street;

Associate Professor of the Department of Computer Technology and Information Security, Kabardino-Balkarian State University named after Kh.M. Berbekov;

360004, Russia, Nalchik, 173 Chernyshevsky street;

pshenokova_inna@mail.ru, ORCID: <https://orcid.org/0000-0003-3394-7682>, SPIN-code: 3535-2963

Murat R. Kiyasov, 4th year Student in the Field of Informatics and Computer Science; Kabardino-Balkarian State University named after Kh.M. Berbekov;

360004, Russia, Nalchik, 173 Chernyshevsky street;

myrat7450@mail.ru