

УДК 004.931; 004.032.26

DOI: [10.26102/2310-6018/2021.35.4.022](https://doi.org/10.26102/2310-6018/2021.35.4.022)

## Нейросетевые модели в задаче классификации медицинских изображений

Н.А. Щукина<sup>1,2</sup>

<sup>1</sup>Российский экономический университет имени Г.В. Плеханова,  
Москва, Российская Федерация

<sup>2</sup>Финансовый университет при Правительстве Российской Федерации,  
Москва, Российская Федерация

**Резюме.** Работа посвящена построению модели сверточной нейронной сети для распознавания медицинских изображений на примере базы рентгеновских снимков пациентов с установленным диагнозом опухоль мозга. Предложена модель сверточной нейронной сети, архитектура которой включает два сверточных слоя и один полносвязный слой. Проведено сравнение результатов достоверности и точности построенного классификатора с результатами, полученными на основе предварительно обученных моделей VGG-16, VGG-19, Inception-V3, InceptionResNet-V2, ResNet-50, ResNet-152 и Xception. Рассмотренные модели CNN на тестовом наборе данных достигли достоверности распознавания изображений от 95.36 % до 98.84 %. Наивысшей достоверности результатов в решении задачи распознавания опухоли мозга достигли модели VGG-16, VGG-19, Xception и предложенная модель. Однако время обучения построенных моделей различается в зависимости от архитектуры нейронной сети. При этом для предложенной модели CNN не выявленных признаков заболевания среди образцов рентгеновских снимков пациентов с установленным диагнозом опухоль мозга оказалось 0.783 %. Предложенная нейросетевая модель может выступать как дополнительный инструмент врача при диагностике опухоли головного мозга. Внедрение алгоритмов компьютерного зрения в ежедневную работу врача позволит оперативно провести дообследование пациента, поставить диагноз и своевременно провести лечение. Применение сервисов на основе алгоритмов искусственного интеллекта способно сократить общее время на проведение диагностических исследований, выявить патологии на ранней стадии заболевания и с большей вероятностью ожидать, что лечение приведет к положительным результатам.

**Ключевые слова:** сверточные нейронные сети, распознавание изображений, классификация изображений, опухоль мозга, предобученные нейронные сети.

**Для цитирования:** Щукина Н.А. Нейросетевые модели в задаче классификации медицинских изображений. *Моделирование, оптимизация и информационные технологии*. 2021;9(4).  
Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1028> DOI: 10.26102/2310-6018/2021.34.3.022

## Neural network models in the problem of medical images classification

N.A. Shchukina<sup>1,2</sup>

<sup>1</sup>Plekhanov Russian University of Economics, Moscow, Russian Federation

<sup>2</sup>Financial University under the Government of the Russian Federation,  
Moscow, Russian Federation

**Abstract:** The research is devoted to the construction of a convolutional neural network model for recognizing medical images on the example of X-ray images database of patients with an established diagnosis of brain tumor. The convolutional neural network model is proposed, the architecture of which includes two convolutional layers and one fully connected layer. The accuracy results of the proposed

classifier and accuracy results of the pre-trained models VGG16, VGG19, Inception-V3, InceptionResNet-V2, ResNet50, ResNet152 and Xception are compared. The considered CNN models on the test dataset achieved the image recognition accuracy from 95.36% to 98.84%. The highest accuracy of the results in solving the problem of recognizing a brain tumor was achieved by the models VGG 16, VGG 19, Xception and the proposed model. However, the training time of the constructed models differs depending on the architecture of the neural network. At the same time, for the proposed CNN model, there were 0.783% of not detected disease signs among the X-ray samples of patients with an established diagnosis of a brain tumor. The proposed neural network model can act as an additional tool for a doctor in the diagnosis of a brain tumor. The introduction of computer vision algorithms into the daily work of a doctor will make it possible to promptly carry out an additional examination of the patient, make a diagnosis and administer treatment in a timely manner. The use of services based on artificial intelligence algorithms can reduce the total time spent on diagnostic studies, identify pathologies at an early stage of the disease and are more likely to guarantee that treatment will lead to positive results.

**Keywords:** convolutional neural networks, image recognition, image classification, brain tumor, pretrained neural networks.

**For citation:** Shchukina N.A. Neural network models in the problem of medical images classification. *Modeling, Optimization and Information Technology*. 2021;9(4). Available from: <https://moitvivt.ru/ru/journal/pdf?id=1028> DOI: 10.26102/2310-6018/2021.34.3.022 (In Russ).

## Введение

В настоящее время цифровые изображения в сфере медицины все чаще используются для диагностики различных патологий. Раннее выявление опухолей головного мозга важно для эффективного лечения заболевания. Однако классификация опухолей головного мозга не является тривиальной задачей. Общепринятым методом выявления и классификации опухолей головного мозга является обследование человека, которое в значительной степени зависит от опыта рентгенологов, которые рассматривают и анализируют характеристики изображений. Кроме того, методы классификации с помощью оператора непрактичны для больших объемов данных и также невоспроизводимы. Поэтому для решения этих проблем крайне желательно использовать средства компьютерной диагностики. Для классификации опухолей головного мозга как правило решают две разные задачи: классификация изображений на нормальные и аномальные классы и классификация аномальных изображений мозга по различным типам патологий.

Все виды опухолей мозга представляют серьезную угрозу здоровью, так как мозг контролирует все функции организма. Как доброкачественные, так и злокачественные новообразования мозга могут в значительной степени нарушать функции организма и быть смертельными. Опухоли головного мозга диагностировать достаточно сложно, так как большинство симптомов заболевания могут быть ошибочно приняты за симптомы менее серьезных заболеваний. Поэтому диагностика опухоли головного мозга на ранней стадии важна. Это позволяет с большей вероятностью ожидать, что лечение приведет к положительным результатам. Поздние стадии заболевания трудно поддаются лечению, а само лечение может привести к побочным реакциям или повреждениям головного мозга.

В настоящее время возможности применения алгоритмов машинного обучения и глубоких нейронных сетей для обработки медицинских изображений посвящено большое количество различных исследований. Методы глубокого обучения широко применяются для обнаружения и сегментации внутренних органов и их патологий [1,2,3,4,5]. Одной из сложностей применения методов искусственного интеллекта в

сфере медицины, с которой сталкиваются большинство исследователей, является недостаточный объем входных данных для обучения применяемых алгоритмов, а также качественное описание результатов медицинских обследований для будущей классификации. Одним из решений проблемы повышения точности распознавания изображений при недостатке входных данных является перенос обучения. Как правило, исследователи используют наиболее известные модели сверточных нейронных сетей, обученных на миллионах различных изображений, среди которых VGG-16, VGG-19 [6], Inception-v3 [7], ResNet 50 [8], EfficientNet [9] и другие.

В исследовании [10] авторам на примере архитектур AlexNet, GoogLeNet и VGGNet методами переноса обучения удалось добиться 98.69 % достоверности распознавания опухолей головного мозга для архитектуры VGG-16. В исследовании [11] авторы предложили модель сверточной нейронной сети, показавшей лучшие результаты классификации изображений рентгеновских снимков пациентов с установленным диагнозом опухоль головного мозга по сравнению с предварительно обученными моделями VGG-16, ResNet-50 и Inception-v3. Таким образом, перенос обучения не всегда позволяет достичь наибольшей достоверности и точности классификатора. Для небольшого объема входных данных процедура аугментации позволяет достичь лучших результатов.

Целью исследования является создание сверточной нейронной сети для классификации рентгеновских снимков головного мозга, обладающей высокой точностью распознавания и скоростью обучения. Также проведем сравнение результатов достоверности и точности построенного классификатора с результатами, полученными на основе предварительно обученных моделей VGG-16, VGG-19, Inception-V3, InceptionResNet-V2, ResNet-50, ResNet-152 и Xception [12].

### Материалы и методы

Набор данных для исследования состоит из 4600 рентгеновских снимков головного мозга, представленных в разных ракурсах [13]. Все данные размечены, то есть определены метки изображений, соответствующих здоровому пациенту и пациенту с установленным диагнозом опухоль головного мозга. Всего в наборе представлено 2087 снимков здоровых пациентов и 2513 снимков пациентов с злокачественными новообразованиями. Представленный датасет является несбалансированным, так как содержит различное число снимков каждого класса, что непременно ухудшает распознавательную способность алгоритмов глубокого обучения. Пример изображений базы данных представлен на Рисунке 1.

Для решения задачи классификации определим два класса изображений: класс 0 – пациент здоров, класс 1 – диагностировано злокачественное новообразование. Для правильной работы нейронной сети необходимо подавать входные данные в виде вектора с координатами в интервале  $[0; 1]$ . Для этого представим входные изображения в виде тензора размерности  $244 \times 244 \times 3$ . Для нормировки данных используем простую процедуру и разделим каждую компоненту входного вектора на 255, что соответствует максимальной интенсивности цвета. На выходе получим вещественные числа в диапазоне от 0 до 1. Таким образом, получаем подготовленный набор данных для построения нейронной сети. Разделим весь набор данных на обучающую, валидационную и тестовую выборки. В обучающую выборку включим 70 % всех изображений, т. е. 3220 образцов, выбранных случайным образом из всего набора. Для валидации из обучающего множества выберем случайным образом 20 % изображений. В выборку для тестирования включаем оставшиеся 1380 рентгеновских снимков.

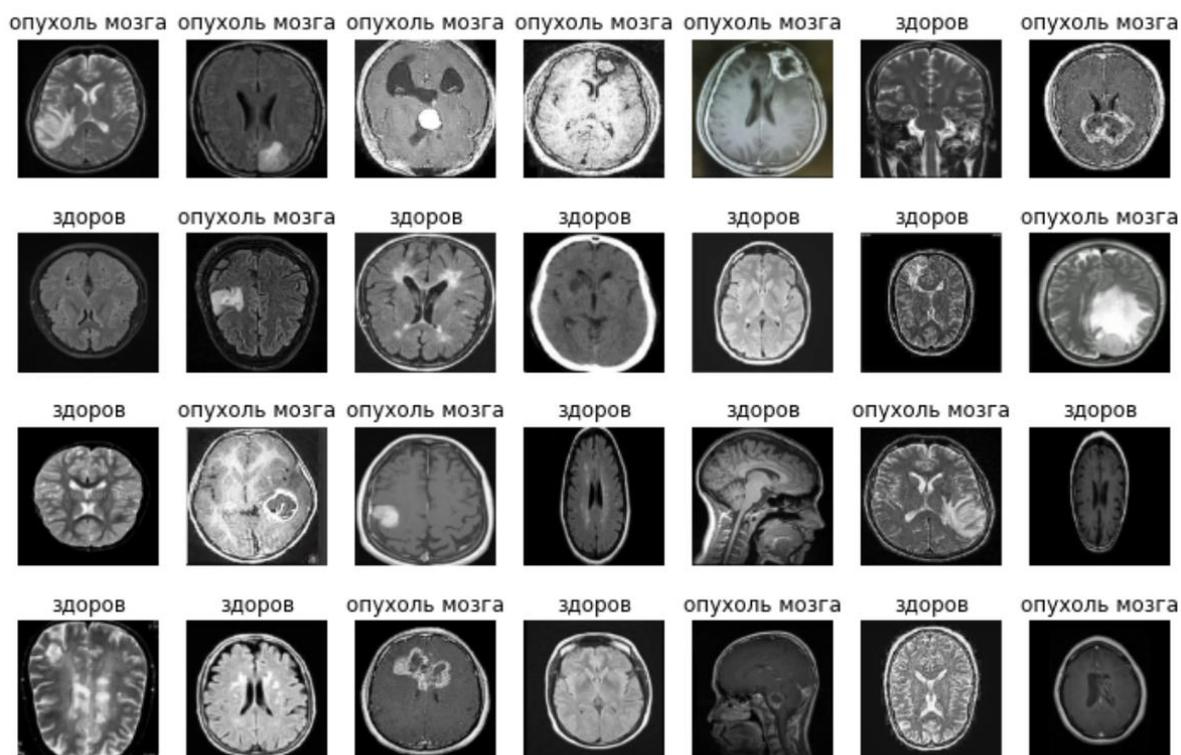


Рисунок 1 – Примеры изображений рентгеновских снимков головного мозга  
Figure 1 – Examples of brain X-ray images

Источник: составлено автором  
Source: Author

Наиболее эффективной для распознавания изображений является архитектура сверточной нейронной сети (Convolutional Neural Networks, CNN). Сверточные нейронные сети обычно состоят из трех основных типов слоев: слоев свертки, слоев пулинга и полносвязных слоев. Основное назначение сверточного слоя заключается в выделении основных признаков изображения и сформирование так называемой карты признаков. Основное назначение слоя пулинга – уменьшение пространства признаков при сохранении наиболее важной информации. Наиболее часто используется слой максупулинга. Полносвязный слой – слой, выходные нейроны которого связаны со всеми входными нейронами. Если полносвязный слой находится в конце проектируемой сети перед слоем классификации, то количество выходных нейронов должно соответствовать количеству выходных классов сети. В качестве функции активации слоя, в котором используется поэлементная нелинейность, будем использовать функцию ReLU (Rectified Linear Unit):

$$f(x) = \max(0; x) = \begin{cases} x, & x > 0, \\ 0, & x \leq 0, \end{cases} \quad (1)$$

где  $x$  – значение входного нейрона на входе полносвязного слоя.

Для решения задачи классификации изображений пациентов с установленным диагнозом опухоль мозга построим простую архитектуру сверточной нейронной сети, представленной двумя сверточными слоями и одним полносвязным слоем. На вход нейронной сети подаются изображения в виде набора RGB пикселей, которые содержат интенсивность красного (Red), зеленого (Green) и синего (Blue) цветов. Различные сочетания этих цветов позволяют создать весь набор цветного спектра. То есть входной слой сверточной нейронной сети представляет собой матрицу размерности  $W \times H \times D$ , где  $W$  – ширина изображения,  $H$  – высота изображения,  $D$  – глубина, т.е. количество

цветовых каналов. Далее трехмерный тензор поступает на слой свертки размерности 3×3 с числом фильтров 32, после прохождения которого выходной тензор поступает на слой пулинга. Будем использовать слой макспулинга с уменьшением размерности в два раза, т.е. будем рассматривать разбиение матрицы предыдущего слоя на подматрицы размерности 2×2. Сверточный слой и слой макспулинга повторяются и сжатое изображение поступает на полносвязный слой с 128 нейронами, на выходе которого имеем два нейрона по числу классов. Архитектура предложенной модели представлена на Рисунке 2.

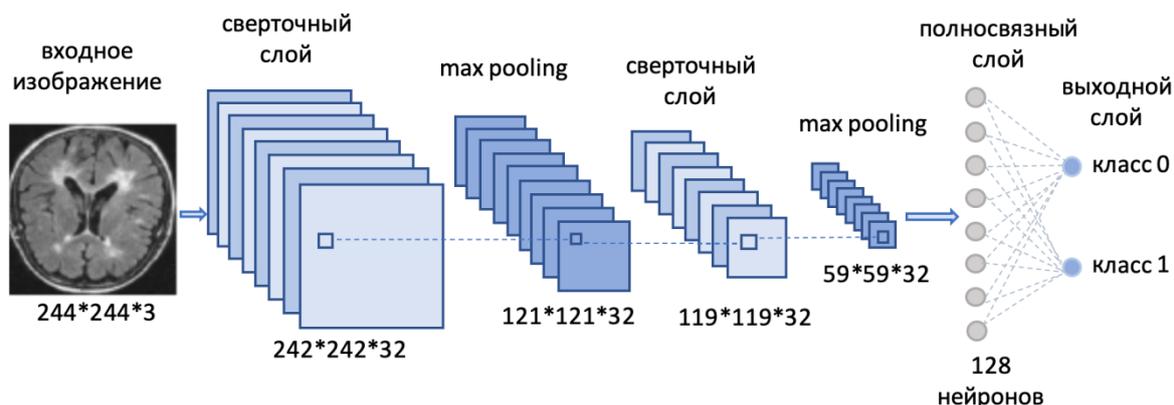


Рисунок 2 – Архитектура предложенной модели CNN  
Figure 2 – Architecture of the proposed CNN model

Источник: составлено автором  
Source: Author

По результатам обучения нейронной сети составим матрицу ошибок (confusion matrix), включающей четыре основные оценки классификации: истинно положительные (True Positive, TP), ложноположительные (False Positive, FP), ложноотрицательный (False Negative, FN) и истинно отрицательные (True Negative, TN). Матрица ошибок позволяет оценить не только ошибки, сделанные классификатором, но и определить тип этих ошибок. Каждый столбец матрицы ошибок соответствует фактическому классу, каждая строка соответствует прогнозируемому классу. Общий вид матрицы ошибок представлен в Таблице 1.

Таблица 1 – Общий вид матрицы ошибок  
Table 1 – General view of the confusion matrix

		Прогнозируемый класс	
		класс 0	класс 1
Истинный класс	класс 0	TN	FP
	класс 1	FN	TP

Полученные оценки позволяют вычислить характеристики качества классификатора: Accuracy (достоверность, аккуратность); Recall, или Sensitivity (полнота, чувствительность); Specificity (специфичность); Precision (точность), F-score (F-мера) по следующим формулам:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (2)$$

$$Recall = Sensitivity = \frac{TP}{TP + FN}, \quad (3)$$

$$Specificity = \frac{TN}{TN + FP}, \quad (4)$$

$$Precision = \frac{TP}{TP + FP}, \quad (5)$$

$$F - score = \frac{2TP}{2TP + FP + FN} = \frac{2Sensitivity \cdot Precision}{Sensitivity + Precision}. \quad (6)$$

F-мера представляет собой среднее гармоническое между полнотой и точностью классификатора и позволяет одновременно измерять полноту и точность и удобна для сравнения моделей.

### Результаты и обсуждение

Проведем обучение предложенной модели. В качестве метода оптимизации градиентного алгоритма выберем оптимизатор adam [14] – метод стохастического градиентного спуска, основанный на адаптивной оценке моментов первого и второго порядка, который подходит для нестационарных задач. Параметр *batchsize*, т. е. количество обучающих примеров за один проход вперед/ назад, установим равным 32. Нейронная сеть будет обучаться пакетами, т. е. после каждых 32 изображений веса полносвязной нейронной сети будут корректироваться. Компьютерную реализацию модели глубокого обучения проведем с помощью библиотеки TensorFlow Python. Все эксперименты по обучению моделей проведем с использованием ноутбука с процессором Intel Core i7 2.4 GHz и 8 ГБ 1600 MHz DDR3. Количество эпох для обучения зависит от момента начала переобучения сети. Процесс обучения построенной модели будем останавливать по отсутствию увеличения достоверности на валидационной выборке в течение трех эпох. В качестве функции потерь выберем функцию категориальной кросс-энтропии, т. к. она лучше подходит для задач множественной классификации. Графики функций потерь и достоверности для обучающей и валидационной выборки, полученной при обучении предложенной модели, приведены на Рисунке 3.

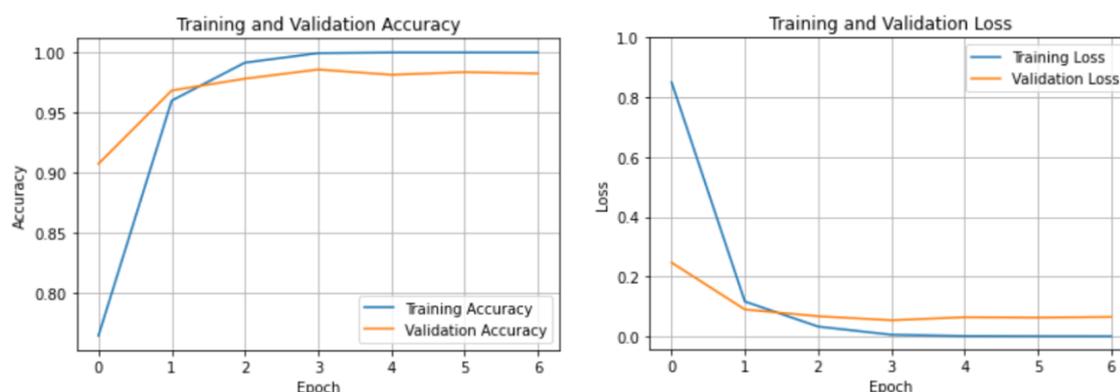


Рисунок 3 – Графики достоверности (аккуратности) и функций потерь обучающей и валидационной выборок предложенной модели

Figure 3 – Graphs of accuracy and losses of training and validation samples of the proposed model  
Источник: составлено автором  
Source: Author

Как видно из Рисунка 3, достоверность (аккуратность) для обучающей выборки и выборки валидации после обучения практически одинаковая. Расхождения графиков функций потерь для обучающей и валидационной выборки не наблюдаем, что говорит

об отсутствии эффекта переобучения сети. Для обучающей выборки потери составили  $4.4134 \cdot 10^{-4}$ , аккуратность (достоверность) составила 1.0000, что свидетельствует о высоком качестве обучения нейронной сети. На валидационной выборке величина функции потерь после обучения составила 0.0650, аккуратность – 0.9826.

На тестовом наборе данных достоверность (аккуратность) классификатора составила 0.9884058, что свидетельствует о высоком качестве обучения нейронной сети. Оценим результаты распознавания изображений рентгеновских снимков пациентов по матрице ошибок. В исследуемом наборе данных наблюдается дисбаланс, то есть количество образцов в классе здоровых пациентов (класс 0) меньше, чем образцов в классе пациентов с установленным диагнозом опухоль мозга (класс 1). При случайном отборе образцов изображений в тестовую выборку вошло 1380 образцов рентгеновских снимков, из которых 614 рентгеновских снимков соответствуют снимкам здоровых пациентов и 766 снимков пациентов с установленным диагнозом опухоль мозга. На Рисунке 4 представлена матрица ошибок результатов работы построенной нейросетевой модели.

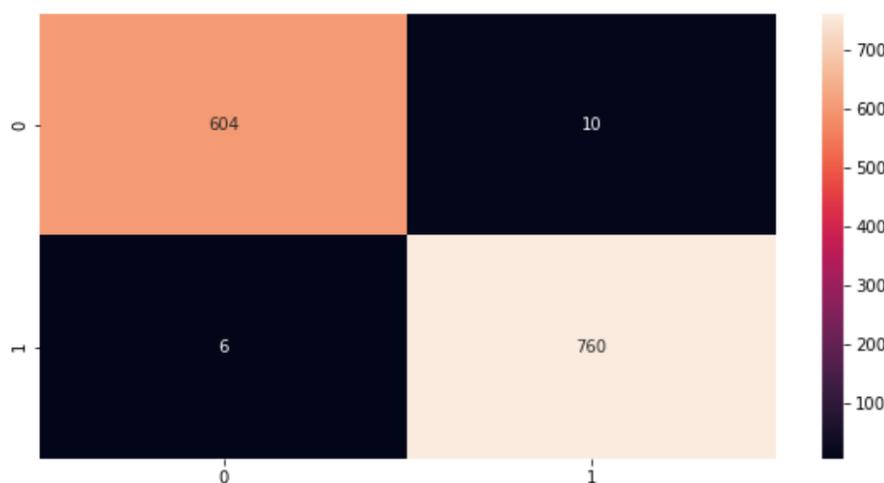


Рисунок 4 – Матрица ошибок предложенной модели CNN

Figure 4 – Confusion matrix of the proposed CNN model

Источник: составлено автором

Source: Author

Видим, что из 614 изображений здоровых пациентов, отобранных для тестовой выборки, 10 образцов были распознаны неверно, т. е. нейронная сеть отнесла эти изображения рентгеновских снимков к классу 1, т. е. к пациентам с установленным диагнозом опухоль мозга. Из 766 изображений пациентов с установленным диагнозом опухоль мозга, отобранных для тестовой выборки, 6 образцов были распознаны неверно, т. е. нейронная сеть отнесла эти изображения рентгеновских снимков к классу здоровых пациентов, т. е. нейронная сеть не смогла выявить наиболее характерные признаки заболевания. Таким образом, можем сказать, что 1.629 % образцов рентгеновских снимков здоровых пациентов были классифицированы неверно и 0.783 % снимков пациентов с установленным диагнозом опухоль мозга не были выявлены нейронной сетью.

Для оценки качества обучения предложенной модели сравним полученные результаты с результатами обучения нейросетевых моделей, предварительно обученных нейронных сетей. Эти модели были созданы и обучены исследователями на наборе ImageNet [15], содержащем более 14 млн. аннотированных изображений, разделенных на более 20 тысяч категорий (классов). Рассмотрим модели VGG-16, VGG-19, Inception-V3,

InceptionResNet-V2, ResNet-50, ResNet-152 и Xception. От каждой из рассматриваемых моделей будем использовать только сверточную часть, которая отвечает за выделение характерных признаков изображений. Полносвязный слой предварительно обученных моделей, который отвечает за классификацию, изменим на два полносвязных слоя с 128 и двумя нейронами соответственно. Проведем дообучение полносвязных слоев моделей предварительно обученных нейронных сетей VGG-16, VGG-19, Inception-V3, InceptionResNet-V2, ResNet-50, ResNet-152 и Xception и по результатам этого обучения на основании полученных матриц ошибок определим основные метрики качества классификаторов. Применяя формулы (2)-(6), вычислим достоверность, точность, чувствительность, полноту и F-меру. Результаты вычислений представлены в Таблице 2.

Таблица 2 – Сравнение метрик качества предложенной модели классификатора и предварительно обученных нейронных сетей

Table 2 – Comparison of quality metrics of the proposed classifier model and trained neural networks

модель	TP	TN	FP	FN	Accuracy	Sensitivity	Specificity	Precision	F-measure	Время обучения, с	Количество параметров модели (обучаемых)
VGG-16	755	609	5	11	0.98841	0.98564	0.99186	0.99342	0.98952	16787	17926338 (3211650)
VGG-19	754	610	4	12	0.98841	0.98433	0.99349	0.99472	0.98950	29712	23236034 (3211650)
Inception-V3	752	611	3	14	0.98768	0.98172	0.99511	0.99603	0.98882	4076	31240354 (9437570)
Inception ResNet-V2	751	609	5	15	0.98551	0.98042	0.99186	0.99339	0.98686	9876	61415010 (7078274)
ResNet-50	743	603	11	23	0.97536	0.96997	0.98208	0.98541	0.97763	15881	40365314 (16777602)
ResNet-152	759	557	57	7	0.95362	0.99086	0.90717	0.93015	0.95954	30639	75148546 (16777602)
Xception	755	609	5	11	0.98841	0.98564	0.99186	0.99342	0.98952	7625	37639082 (16777602)
Предложенная модель	760	604	10	6	0.98841	0.99217	0.98371	0.98701	0.98958	955	14268706 (14268706)

Источник: составлено автором

Source: Author

Сравнивая результаты обучения предложенной модели и моделей предварительно обученных нейронных сетей, можем сделать вывод о высоком качестве построенного

классификатора. Наибольшую достоверность при распознавании изображений рентгеновских снимков пациентов с установленным диагнозом опухоль мозга показали модели VGG16, VGG19, Xception и предложенная модель. Следует отметить, что время обучения предложенной модели по сравнению со временем обучения предварительной обученных моделей оказалось значительно меньше.

Задача классификации изображений снимков головного мозга является достаточно популярной у исследователей. Поэтому проведем сравнение полученных результатов классификации предложенной в данной исследовании модели с моделями, предложенными другими исследователями. Результаты сравнения моделей классификации изображений снимков головного мозга пациентов с установленным диагнозом опухоль мозга представлены в Таблице 3.

Таблица 3 – Сравнение результатов классификации различных моделей  
Table 3 – Comparison of classification results of different models

Модель	Общее количество образцов в исследуемом датасете	Задача исследования	Accuracy, %	Recall, %	Specificity, %	Precision, %	F-measure, %
CNN [11]	253	Классификация изображений с опухолью и без опухоли	100.00	100.00	100.00	100.00	100.00
Дифференциальная глубокая CNN [16]	25000	Классификация изображений с опухолью и без опухоли	99.25	95.89	93.75	97.22	95.23
CNN [17]	66	Классификация глиомы, менингиомы и опухолей гипофиза	90.00 (100.00)	93.33 (100)	80.00 (100.00)	93.33 (100.00)	93.33 (100.00)
CNN [18]	3064	Классификация глиомы, менингиомы и опухолей гипофиза	97.3	94.0	73.39	96.7	82.8
CNN [19]	3064	Классификация глиомы, менингиомы и опухолей гипофиза	94.39	93.00	-	93.33	93.17
CNN [20]	3064	Классификация глиомы, менингиомы и опухолей гипофиза	98.77	98.61	99.33	98.76	98.68
CNN [21]	243	Классификация изображений с опухолью и без опухоли	97.5	-	-	-	-
DeepMedic (inputs: T1+T2) [22]	243	Классификация изображений глиомы и глиобластомы	-	-	-	-	83.17

DeepMedic (inputs: T1+T2) + DeepMedic (inputs: T1) + WNet [22]	243	Классификация изображений глиомы и глиобластомы	-	-	-	-	88.23
Ансамбли из пред-обученных CNN + ML [23]	253	Классификация изображений с опухолью и без опухоли	96.08	-	-	-	-
Ансамбли из пред-обученных CNN + ML [23]	3000	Классификация изображений с опухолью и без опухоли	98.83	-	-	-	-
Ансамбли из пред-обученных CNN + ML [23]	3264	Классификация изображений с опухолью и без опухоли	93.72	-	-	-	-
Предложенная модель CNN	4600	Классификация изображений с опухолью и без опухоли	98.84	99.22	98.37	98.70	98.96

Источник: составлено автором на основании исследований [11, 16-23]  
Source: compiled by the author based on research [11, 16-23]

Как видно из Таблицы 3, большинство моделей для классификации изображений опухоли мозга, представленных различными исследованиями, достигают высоких показателей распознавания изображений. Для сравнения моделей удобнее всего использовать показатель F-меры. В исследовании [11] F-мера достигла 100 %, однако следует учесть, что этот показатель был получен на небольшом наборе данных, где в тестовую выборку было включено лишь 20 образцов. Результаты классификации опухоли мозга исследования [17] также были получены на небольшом наборе данных. Здесь исследуемый набор изображений содержит 66 образцов, который был разбит на два валидационных датасета по 20 изображений в каждом. Таким образом, проводя сравнительный анализ результатов классификации, можно сделать вывод о том, что предложенная в работе модель не уступает по своим качественным характеристикам как предварительно обученным моделям, так и моделям, предложенным различными исследователями. Следует отметить, что предложенная модель имеет более простую архитектуру сверточной нейронной сети, содержит меньшее количество гиперпараметров, что значительно уменьшает время ее обучения.

### Заключение

Рассмотрена задача классификации на примере изображений рентгеновских снимков пациентов с установленным диагнозом опухоль мозга. Для решения задачи классификации построена модель сверточной нейронной сетей, архитектура которой состоит из двух сверточных и одного полносвязного слоев. По результатам обучения проведено сравнение метрик качества классификатора предложенной модели с метриками предварительно обученных сверточных нейронных сетей. Наивысшей достоверности результатов в решении задачи распознавания опухоли мозга достигли модели VGG16, VGG 19, Xception и предложенная модель. Рассмотренные модели CNN на тестовом наборе данных достигли достоверности распознавания изображений от 95.36 % до 98.84 %. Однако время обучения построенных моделей различается в зависимости от архитектуры нейронной сети. Построенные нейросетевые модели могут выступать как дополнительный инструмент врача при диагностике опухоли головного

мозга. Внедрение алгоритмов компьютерного зрения в ежедневную работу врача позволит оперативно провести дообследование пациента, поставить диагноз и своевременно провести лечение. Применение сервисов на основе алгоритмов искусственного интеллекта способно сократить общее время на проведение диагностических исследований, выявить патологии на ранней стадии заболевания и с большей вероятностью ожидать, что лечение приведет к положительным результатам.

### СПИСОК ИСТОЧНИКОВ

1. Солодовников В.И., Бочкарев П.В., Кузьмицкий А.А., Газов А.И., Панищев В.С., Сирота Е.С. Алгоритмы распознавания органов на изображениях мультиспиральной компьютерной томографии. *Биомедицинская радиоэлектроника*. 2019;22(7):39–46. DOI: 10.18127/j15604136-201907-05
2. Эль-Хатиб С.А., Скобцов Ю.А. Компьютерная система сегментации медицинских изображений методом муравьиных колоний. *Радиоэлектроника, информатика, управление*. 2015;3:49–57. DOI 10.15588/1607-3274-2015-3-6
3. Danilov V.V., Gerget O.M., Skirnevskiy I.P., Manakov R.A., Kolpashchikov D.Y. Segmentation based on propagation of dynamically changing superpixels. *Programming and Computer Software*. 2020;46(3):195–206. DOI: 10.31857/S0132347420030048
4. Khvostikov A., Krylov A., Mikhailov I., Kharlova O., Oleynikova N., Malkov P. Automatic mucous glands segmentation in histological images. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W12, 2019. Int. Worksh. on “Photogrammetric & Computer Vision Techniques for Video Surveillance, Biometrics and Biomedicine”, 13-15 May 2019, Moscow, Russia.
5. Bakas S., Reyes M., Jakab A., Bauer S., Rempfler M., Crimi A. et al., Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge, arXiv preprint arXiv:1811.02629, 2018.
6. Simonyan K. & Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint: arXiv 1409.1556, 2014. Доступно по: <https://arxiv.org/pdf/1409.1556.pdf> (дата обращения 06.10.2021)
7. Szegedy C., Vanhoucke V., Ioffe S., Shlens J. Rethinking the Inception Architecture for Computer Vision. arXiv preprint: arXiv:1512.00567v3, 2015. Доступно по: <https://arxiv.org/pdf/1512.00567v3.pdf> (дата обращения 06.10.2021)
8. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition. arXiv preprint: arXiv: 1512.03385v1, 2015. Доступно по: <https://arxiv.org/pdf/1512.03385.pdf> (дата обращения 06.10.2021)
9. Mingxing Tan, Quoc V. Le. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. arXiv preprint: arXiv: 1905.11946v5, 2020. Доступно по: <https://arxiv.org/pdf/1905.11946v5.pdf> (дата обращения 06.10.2021)
10. Rehman, A., Naz, S., Razzak, M.I. et al. A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning. *Circuits, Systems, and Signal Processing*. 2020;39:757–775. <https://doi.org/10.1007/s00034-019-01246-3>
11. Hassan Ali Khan, Wu Jue, Muhammad Mushtaq and Muhammad Umer Mushtaq. Brain tumor classification in MRI image using convolutional neural network. *Mathematical Biosciences and Engineering*. 2020;17(5):6203–6216. DOI: 10.3934/mbe.2020328
12. Доступные модели приложений Keras. Доступно по: <https://keras.io/api/applications/> (дата обращения 06.05.2021).
13. База данных изображений рентгеновских снимков головного мозга. Доступно по: <https://www.kaggle.com/preetviradiya/brian-tumor-dataset> (дата обращения 06.05.2021)

14. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization. Proceedings of the 3rd International Conference on Learning Representations (ICLR). arXiv preprint arXiv:1412.6980, 2014.
15. База данных изображений ImageNet. Доступно по: <https://www.image-net.org/update-mar-11-2021.php> (дата обращения 06.05.2021).
16. Abd El Kader, I.; Xu, G.; Shuai, Z.; Saminu, S.; Javaid, I.; Salim Ahmad, I. Differential Deep Convolutional Neural Network Model for Brain Tumor Classification. *Brain Sciences*. 2021;11:352. <https://doi.org/10.3390/brainsci11030352>
17. Shaik Basheera and M. Satya Sai Ram. Classification of Brain Tumors Using Deep Features Extracted Using CNN. Journal of Physics: Conf. Series 1172 (2019) 012016 International Conference on Applied Physics, Power and Material Science. DOI: 10.1088/1742-6596/1172/1/012016
18. Díaz-Pernas F.J., Martínez-Zarzuela M., Antón-Rodríguez M., González-Ortega D.A. Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network. *Healthcare*. 2021;9:153. <https://doi.org/10.3390/healthcare9020153>
19. Das S., Aranya O.F.M.R.R. and Labiba N.N. Brain Tumor Classification Using Convolutional Neural Network. 2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT), 3-5 May 2019, Dhaka, Bangladesh. 2019, DOI: 10.1109/ICASERT.2019.8934603.
20. Ali Mohammad Alqudah, Hiam Alquraan, Isam Abu Qasmieh, Amin Alqudah, Wafaa Al-Sharu. Brain Tumor Classification Using Deep Learning Technique – A Comparison between Cropped, Uncropped, and Segmented Lesion Images with Different Sizes *International Journal of Advanced Trends in Computer Science and Engineering*. 2019;8(6):3684–3691.
21. Seetha J., Raja S.S. Brain Tumor Classification Using Convolutional Neural Networks. *Biomed Pharmacology Journal*. 2018;11(3). DOI: <https://dx.doi.org/10.13005/bpj/1511>
22. Мусатян С.А., Ломакин А.В., Сартасов С.Ю., Попыванов Л.К., Монахов И.Б., Чижова А.С. Способы сегментации медицинских изображений. *Труды Института системного программирования РАН*. 2018;30(4):183–194. [https://doi.org/10.15514/ISPRAS-2018-30\(4\)-12](https://doi.org/10.15514/ISPRAS-2018-30(4)-12)
23. Kang J., Ullah Z., Gwak J. MRI-Based Brain Tumor Classification Using Ensemble of Deep Features and Machine Learning Classifiers. *Sensors*. 2021;21:2222. <https://doi.org/10.3390/s21062222>

## REFERENCES

1. Solodovnikov V.I., Bochkarev P.V., Kuzmitsky A.A., Glazov A.I., Spanish chef V.S., Sirota E.S. Recognition algorithms for organs in multispiral computed tomography. *Biomeditsinskaya radioelektronika = Biomedical Radioelectronics*. 2019;22(7):39-46. (In Russ.) DOI: 10.18127/j15604136-201907-05
2. El-Khatib S.A., Skobtsov Y. A. The computer system of medical image segmentation by ant colony optimization. *Radioelektronika, informatika, upravleniye = Radio Electronics, Computer Science, Control*. 2015;3:49–57. (In Russ.) DOI 10.15588/1607-3274-2015-3-6.
3. Danilov V.V., Gerget O.M., Skirnevskiy I.P., Manakov R.A., Kolpashchikov D.Y. Segmentation based on propagation of dynamically changing superpixels. *Programming and Computer Software*. 2020;46(3):195-206. DOI: 10.31857/S0132347420030048
4. Khvostikov A., Krylov A., Mikhailov I., Kharlova O., Oleynikova N., Malkov P. Automatic mucous glands segmentation in histological images. The International Archives of the

- Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W12, 2019. Int. Worksh. on “Photogrammetric & Computer Vision Techniques for Video Surveillance, Biometrics and Biomedicine”, 13-15 May 2019, Moscow, Russia.
5. Bakas S., Reyes M., Jakab A., Bauer S., Rempfler M., Crimi A. et al., Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge, arXiv preprint arXiv:1811.02629, 2018.
  6. Simonyan K. & Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint: arXiv 1409.1556, 2014. Available at: <https://arxiv.org/pdf/1409.1556.pdf> (accessed 06.10.2021).
  7. Szegedy C., Vanhoucke V., Ioffe S., Shlens J. Rethinking the Inception Architecture for Computer Vision. arXiv preprint: arXiv:1512.00567v3, 2015. Available at: <https://arxiv.org/pdf/1512.00567v3.pdf> (accessed 06.10.2021).
  8. Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun. Deep Residual Learning for Image Recognition. arXiv preprint: arXiv: 1512.03385v1, 2015. Available at: <https://arxiv.org/pdf/1512.03385.pdf> (accessed 06.10.2021).
  9. Mingxing Tan, Quoc V. Le. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. arXiv preprint: arXiv: 1905.11946v5, 2020. Available at: <https://arxiv.org/pdf/1905.11946v5.pdf> (accessed 06.10.2021).
  10. Rehman A., Naz S., Razzak M.I. et al. A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning. *Circuits, Systems, and Signal Processing*. 2020;39:757–775. <https://doi.org/10.1007/s00034-019-01246-3>
  11. Hassan Ali Khan, Wu Jue, Muhammad Mushtaq and Muhammad Umer Mushtaq. Brain tumor classification in MRI image using convolutional neural network. *Mathematical Biosciences and Engineering*. 2020;17(5):6203-6216. DOI: 10.3934/mbe.2020328
  12. Available models Keras Applications. Available at: <https://keras.io/api/applications/> (accessed 06.05.2021). (In Russ.)
  13. Database of brain X-ray images. Available at: <https://www.kaggle.com/preetviradiya/brian-tumor-dataset> (accessed 06.05.2021). (In Russ.)
  14. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization. Proceedings of the 3rd International Conference on Learning Representations (ICLR). arXiv preprint arXiv:1412.6980, 2014.
  15. Database of ImageNet. Available at: <https://www.image-net.org/update-mar-11-2021.php> (accessed 06.05.2021). (In Russ.)
  16. Abd El Kader I., Xu G., Shuai Z., Saminu S., Javaid I., Salim Ahmad I. Differential Deep Convolutional Neural Network Model for Brain Tumor Classification. *Brain Sciences*. 2021;11:352. <https://doi.org/10.3390/brainsci11030352>
  17. Basheer Shaik and M. Satya Sai Ram. Classification of Brain Tumors Using Deep Features Extracted Using CNN. Journal of Physics: Conf. Series 1172 (2019) 012016 International Conference on Applied Physics, Power and Material Science. DOI: 10.1088/1742-6596/1172/1/012016
  18. Díaz-Pernas F.J., Martínez-Zarzuela M., Antón-Rodríguez M., González-Ortega D. A. Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network. *Healthcare*. 2021;9:153. <https://doi.org/10.3390/healthcare9020153>
  19. Das S., Aranya O.F.M.R.R. and Labiba N.N. Brain Tumor Classification Using Convolutional Neural Network. 2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT), 3-5 May 2019, Dhaka, Bangladesh. 2019, DOI: 10.1109/ICASERT.2019.8934603.
  20. Ali Mohammad Alqudah, Hiam Alquraan, Isam Abu Qasmieh, Amin Alqudah, Wafaa Al-

- Sharu. Brain Tumor Classification Using Deep Learning Technique – A Comparison between Cropped, Uncropped, and Segmented Lesion Images with Different Sizes *International Journal of Advanced Trends in Computer Science and Engineering*. 2019;8(6):3684–3691.
21. Seetha J., Raja S.S. Brain Tumor Classification Using Convolutional Neural Networks. *Biomed Pharmacology Journal*. 2018;11(3). DOI: <https://dx.doi.org/10.13005/bpj/1511>
22. Musatian S.A., Lomakin A.V., Sartasov S.Yu., Popyvanov L.K., Monakhov I.B., Chizhova A.S. Medical Images Segmentation Operations. *Trudy Instituta sistemnogo programmirovaniya RAN = Proceedings of the Institute for System Programming of the RAS (Proceedings of ISP RAS)*. 2018;30(4):183–194. (In Russ.) DOI: [https://doi.org/10.15514/ISPRAS-2018-30\(4\)-12](https://doi.org/10.15514/ISPRAS-2018-30(4)-12)
23. Kang J., Ullah Z., Gwak J. MRI-Based Brain Tumor Classification Using Ensemble of Deep Features and Machine Learning Classifiers. *Sensors*. 2021;21:2222. <https://doi.org/10.3390/s21062222>

### ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Щукина Наталья Александровна**, к.т.н., доцент, кафедра математических методов в экономике, Российский экономический университет им. Г. В. Плеханова, Москва, Российская Федерация.

Доцент, Департамент Анализа данных и машинного обучения, Финансовый университет при правительстве Российской Федерации, Москва, Российская Федерация.

*e-mail:* [shchukinan@yandex.ru](mailto:shchukinan@yandex.ru)

ORCID: [0000-0002-5825-1051](https://orcid.org/0000-0002-5825-1051)

**Natalia A. Shchukina**, Phd In Engineering, Associate Professor of Mathematical Methods In Economics, Plekhanov Russian University of Economics, Moscow, Russian Federation.

Associate Professor, Department of Data Analysis and Machine Learning, Financial University Under The Government of The Russian Federation, Moscow, Russian Federation.

*Статья поступила в редакцию 30.07.2021; одобрена после рецензирования 15.12.2021; принята к публикации 29.12.2021.*

*The article was submitted 30.07.2021; approved after reviewing 15.12.2021; accepted for publication 29.12.2021.*