

НЕЙРОСЕТЕВОЙ КЛАССИФИКАТОР РЕНТГЕНОВСКИХ ИЗОБРАЖЕНИЙ ГРУДНОЙ КЛЕТКИ ДЛЯ ОБНАРУЖЕНИЯ ПРИЗНАКОВ COVID-19 ПНЕВМОНИИ

Л. Ю. Кривоногов¹, И. С. Иномбоев², Ю. П. Чебан³

^{1, 2}Пензенский государственный университет, Пенза, Россия

³Пензенская областная клиническая больница имени Н. Н. Бурденко, Пенза, Россия

¹leonidkrivonogov@yandex.ru, ²ilhomdzoninomboev@gmail.com,

³petrunina_julija@inbox.ru

Аннотация. Актуальность и цели. Рассматривается разработка нейросетевого бинарного классификатора рентгеновских изображений грудной клетки, позволяющего обнаружить характерные признаки пневмонии, вызванных COVID-19. Приведены доводы в пользу применения рентгенографии как альтернативы компьютерной томографии при выявлении изменений в легких, характерных для COVID-19. Проведен анализ публикаций в области автоматической классификации рентгеновских изображений с признаками COVID-19 пневмонии. Материалы и методы. Для обучения и тестирования модели использовался авторский набор данных, состоящий из 1240 рентгеновских изображений грудной клетки. Обучающая часть набора данных была подвергнута процедуре аугментации. Предложена оригинальная четырнадцатислойная модель классификатора. Обучение модели проходило в течение 20 эпох. Результаты. Оценка качества классификации проведена при помощи стандартных метрик. Были получены следующие значения метрик: Sensitivity (Recall) – 95,4 %, Specificity – 97,8 %, Accuracy – 96,7 %, Precision – 96,6 %, F1-scope – 96 %. Дополнительное тестирование модели было проведено на 228 изображениях базы COVID-19 Radiography Database платформы Kaggle, при этом получены следующие значения метрик: Sensitivity (Recall), Specificity, Accuracy – 96 %, Precision – 93 %, F1-scope – 94 %. Выводы. Качество классификации рентгеновских изображений грудной клетки разработанной моделью соответствует современному уровню и достаточно близко к врачебному. Разработанный классификатор может быть использован в практической рентгенологии в качестве нейросетевого ассистента врача-рентгенолога.

Ключевые слова: искусственная нейронная сеть, глубокое обучение, рентгенография, рентгеновское изображение грудной клетки, COVID-19

Для цитирования: Кривоногов Л. Ю., Иномбоев И. С., Чебан Ю. П. Нейросетевой классификатор рентгеновских изображений грудной клетки для обнаружения признаков COVID-19 пневмонии // Модели, системы, сети в экономике, технике, природе и обществе. 2025. № 3. С. 113–126. doi: 10.21685/2227-8486-2025-3-9

NEURAL NETWORK CLASSIFIER OF CHEST X-RAY IMAGES FOR DETECTING SIGNS OF COVID-19 PNEUMONIA

L.Yu. Krivonogov¹, I.S. Inomboev², Yu.P. Cheban³

^{1, 2}Penza State University, Penza, Russia

³Penza Regional Clinical Hospital named after N.N. Burdenko, Penza, Russia

¹leonidkrivonogov@yandex.ru, ²ilhomdzinomboev@gmail.com,

³petrunina_julija@inbox.ru

Abstract. *Background.* This study presents the development of a neural network-based binary classifier for detecting COVID-related pneumonia in chest X-ray images. Arguments are given in favor of using X-ray as an alternative to computed tomography in detecting abnormalities in the lungs, associated with COVID-19. An analysis of existing publications on automatic classification of X-ray images with signs of COVID-19 pneumonia is conducted. *Materials and methods.* The author's dataset consisting of 1240 chest X-ray images was used to train and test the model. The training part of the dataset was subjected to the augmentation procedure. An original fourteen-layer classifier model was proposed and trained over 20 epochs. *Results.* The classification quality was assessed using standard metrics. The following metric values were obtained: Sensitivity (Recall) – 95,4 %, Specificity – 97,8 %, Accuracy – 96,7 %, Precision – 96,6 %, F1-scope – 96 %. Supplementary testing on 228 images from the COVID-19 Radiography Database of the Kaggle platform demonstrated consistent performance: Sensitivity (Recall), Specificity, Accuracy – 96 %, Precision – 93 %, F1-scope – 94 %. *Conclusions.* The quality of classification of chest X-ray images by the developed model corresponds to the current level and is close enough to the medical one. The developed classifier can be used in clinical radiology practice as an AI-assistant for radiologists.

Keywords: artificial neural network, deep learning, radiography, chest X-ray images, COVID-19

For citation: Krivonogov L.Yu., Inomboev I.S., Cheban Yu.P. Neural network classifier of chest X-ray images for detecting signs of COVID-19 pneumonia. *Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve = Models, systems, networks in economics, technology, nature and society.* 2025;(3):113–126. (In Russ.). doi: 10.21685/2227-8486-2025-3-9

Введение

Во время пандемии коронавирусной инфекции COVID-19 российская национальная система здравоохранения столкнулась с рядом серьезных проблем. Решение некоторых из них, в первую очередь связанных с дефицитом высококвалифицированных врачей-рентгенологов и недостаточной оперативностью диагностики, может быть достигнуто за счет совершенствования методов и систем автоматической интерпретации медицинских изображений.

COVID-19 вызывает высокую температуру, лихорадку, сухой кашель, затрудненное дыхание, утомляемость и может привести к тяжелым осложнениям, вплоть до летального исхода. Довольно часто на фоне среднетяжелой и тяжелой форм COVID-19 развивается пневмония, которая либо вызывается вирусом, либо является следствием иммунной реакции организма на вирус. Коронавирусная пневмония, в отличие от классической бактериальной, имеет иное течение болезни, развивается по особому механизму и затрагивает

другие структурные единицы легких. Она может протекать бессимптомно, не зависит от возраста и сезона, а течение патологического процесса в большинстве случаев приводит к двустороннему поражению легких [1, 2]. COVID-19 пневмония зачастую принимает острую, тяжелую форму, поэтому такое состояние довольно опасно и может угрожать жизни. Очевидно, что подобную пневмонию необходимо выявить как можно раньше [2].

Хотя «основой диагностики COVID-19 во время пандемии являются лабораторные методы» [3], тем не менее «для выявления пневмоний, вызванных коронавирусной инфекцией, а также их осложнений, дифференциальной диагностики с другими заболеваниями легких, определения степени выраженности и динамики изменений, оценки эффективности проводимой терапии широко применяют методы лучевой диагностики» [3].

Наибольшую чувствительность среди методов лучевой диагностики в выявлении изменений в легких, характерных для COVID-19, имеет компьютерная рентгеновская томография (КТ). Несмотря на то, что стандартная рентгенография (РГ) не имеет столь высокой чувствительности в выявлении изменений в легких, как КТ, она является широкодоступным, быстрым и недорогим методом визуализации. Рентгеновское изображение (РИ) грудной клетки (РИГК) позволяет обнаружить характерные признаки COVID-19 пневмонии, такие как двусторонние, периферические и нижнедолевые инфильтраты, а также оценить степень поражения легких и риск ряда осложнений [3]. Существует ряд доводов в пользу применения РГ в качестве альтернативы КТ при выявлении изменений в легких, характерных для COVID-19: высокая лучевая нагрузка при КТ, превышающая лучевую нагрузку при РГ в 50–350 раз; стоимость проведения КТ превышает стоимость РГ как минимум в 3–4 раза; стоимость компьютерных томографов в 5–10 раз превышает стоимость рентгеновских аппаратов, а их распространенность в России все еще недостаточна.

Несмотря на доступность получения РИГК, их интерпретация требует значительных временных затрат, большого опыта и высокой квалификации врача-рентгенолога, что значительно ограничивает массовое применение рентгенографии грудной клетки для диагностики COVID-19 во время пандемии. Создание достоверных методов автоматической интерпретации рентгеновских изображений позволит ослабить или даже снять это ограничение.

В настоящее время такая сложная и ответственная задача, как автоматическая интерпретация РИ, не может быть полноценно решена без привлечения технологий искусственного интеллекта и машинного обучения. Наибольшие перспективы применения при реализации систем автоматической интерпретации РИ имеют сверточные нейронные сети глубокого обучения, обладающие достаточно высокой точностью классификации различных изображений, в том числе и медицинских.

Начиная с 2020 г. в мире реализовано несколько десятков проектов в области классификации РИГК с признаками пневмоний, вызванных COVID-19 [4–19]. Пик публикационной активности по этой теме пришелся на 2020/2021 гг., но и после окончания пандемии интерес к этой проблеме снизился незначительно. Авторы исследования провели анализ научных публикаций в области автоматической классификации РИГК с признаками COVID-19 пневмоний, результаты которого представлены в табл. 1.

Таблица 1

Используемые методы и значения метрик качества классификации РИГК

Авторы, ссылка, год	Технологии, методы	Кол-во РИ	Значения метрик качества, %
Hemdan E. E. et al., [4], 2020	COVIDX-Net: объединение моделей VGG19, DenseNet201, InceptionV3, ResNetV2, Inception-Resnet-V2, Xception, MobileNetV2	50	Ac-90, Pr-83, Re-80, F1-89/91
Nishio M. et al., [5], 2020	Трансферное обучение VGG16, аугментация данных	1248	Ac-83,6; Se-90,9
Minaee S. et al., [6], 2020	Трансферное обучение DenseNet-121, SqueezeNet, ResNet50, ResNet18	5000	Se-98, Sp-92,9 (для SqueezeNet)
Wang L. et al., [7], 2020	Авторская модель COVID-Net	13 645	Ac-92,4
Sethy P. K. et al., [8], 2020	ResNet50+SVM	50	Ac-95,4
Bassi, Attux, [9], 2020/2021	Двойное трансферное обучение DenseNet121, DenseNet201 (на ImageNet и РИ)	112 120	Ac-100 (на 150 РИ)
Narin A. et al., [10], 2021	ResNet50, ResNet101, ResNet152, InceptionV3 и Inception-ResNetV2	100	Ac 98 для ResNet50
Ефремцев В. Г. и др., [11], 2021	Авторская CNN	1560	Pr-91, Re-95, F1-93
Shelke A. et al., [12], 2021	Объединение моделей VGG-16, DenseNet-161, ResNet-18	1000	Ac-98,9
Зеленина Л. И. и др., [13], 2021	Авторская CNN	2433	Ac-95
Nigam B. et al., [14], 2021	Трансферное обучение моделей DenseNet121, NASNet, Xception, VGG16, EfficientNet	16 634	Ac-79/93,5
Щетинин Е. Ю., [15], 2022	Трансферное обучение на ImageNet моделей Xception, MobileNetV2, InceptionResNetV2, DenseNet121, ResNet50 и VGG16	15 155	Ac-99, Re-99, Pr-99
Basma W. A., Salman H. M. A., [16], 2022	Авторская модель на основе Xception	2614	Ac-99, Pr-95, Re-92, F1-95
Chow L. S. et al., [17], 2023	Трансферное обучение 18 моделей CNN, включая VGG-19, VGG-16, ShufeNet, SqueezeNet и др.	700	Ac-90,7/94,3 F1-90,8/94,3,
Harun Or Rashid et al., [18], 2023	Авторская CNN	98	Ac-97
Asif S. et al., [19], 2024	Ансамбль 14 моделей CNN. Две стратегии трансферного обучения	3886	Ac-99

В столбце «Кол-во РИ» приведено общее количество изображений, используемых для обучения, проверки и тестирования нейросетевых классификаторов. В столбце «Значения метрик качества, %» представлены значения стандартных метрик качества классификации: Accuracy (Ac), Sensitivity (Se), Specificity (Sp), Precision (Pr), Recall (Re), F1-score (F1).

Для повышения качества классификации РИГК существующие «типовые» модели сверточных нейронных сетей (CNN) зачастую подвергаются различным усовершенствованиям: разрабатываются специальные модифицированные архитектуры [7, 11, 13, 16, 18], используются многообразные варианты объединения моделей (от простого использования нескольких моделей [4, 6, 10, 12, 17] до ансамблевых методов машинного обучения [19]), комбинируются с другими технологиями машинного обучения (например, с SVM в работе [8]).

Одной из основных проблем автоматической интерпретации медицинских изображений с применением глубоких нейронных сетей является недостаточный объем входных данных для обучения моделей. Для задачи классификации РИГК не всегда возможно собрать достаточно большое количество изображений заданных классов. К тому же необходимо обеспечить достаточную сбалансированность и репрезентативность обучающих выборок, что тоже непросто. Кроме того, собранные РИ необходимо аннотировать, а это ответственный и трудоемкий процесс, исключающий полную автоматизацию.

Для решения проблемы недостаточного количества РИГК для обучения моделей многие исследователи [5, 6, 9, 14, 15, 17] применяют трансферное обучение, заключающееся в предварительном обучении модели на миллионах самых различных изображений. Дообучение модели на ограниченном наборе РИГК выполняется значительно быстрее и обычно дает лучшие результаты по сравнению с обычным обучением. При этом сокращаются трудозатраты при обучении и снижаются требования к вычислительным мощностям.

Еще одним методом решения проблемы недостаточного объема данных для обучения моделей является аугментация – увеличение размера обучающей выборки данных за счет генерации новых модифицированных версий существующих данных, что позволяет уменьшить эффект переобучения модели, повысить ее обобщаемость и, соответственно, качество классификации.

Большая часть классификаторов, приведенных в табл. 1, используют различные процедуры предварительной обработки изображений: изменение размера, нормализацию, устранение шумов и артефактов, оценку качества и др.

Что касается выбора модели для классификации РИГК, то в систематическом обзоре [20] показано, что для определения признаков COVID-19 пневмоний чаще всего выбирают модели ResNet, VGG, Xception, Inception, MobileNet, GoogleNet, DenseNet.

Качество классификаций моделей во всех проектах (см. табл. 1) достаточно высокое: значения Accuracy составляют от 80 до 100 %, но сверхвысокие (близкие к 100 %) значения метрик модели обычно показывают на малых тестовых выборках. Несмотря на высокое качество классификации, существуют некоторые ограничения при практическом применении этих разработок, связанные со сложностью, требованиями к вычислительным ресурсам, недостаточной обобщающей способностью ряда моделей.

Целью исследования являются разработка и оценка качества оригинальной модели сверточной нейронной сети для бинарной классификации РИГК, обученной на небольшом наборе изображений, способной с высокой достоверностью выявлять признаки пневмоний, вызванных коронавирусной инфекцией.

Материалы и методы

1. Описание набора данных для обучения и тестирования. Для обучения, тестирования и верификации нейросетевого классификатора был подготовлен набор данных (DataSetA), содержащий 1240 обезличенных РИГК, собранных авторами. Этот набор данных включал 555 рентгеновских изображений здоровых пациентов (класс «Normal») и 685 изображений с признаками COVID-19 (класс «Covid»), принадлежащих пациентам с подтвержденным диагнозом COVID-19. Набор данных был разделен на обучающую, тестовую и контрольную (валидационную) части. Структура DataSetA представлена в табл. 2.

Таблица 2

Структура авторского набора РИГК (DataSetA)

Части набора данных	Количество РИГК класса «Normal»	Количество РИГК класса «Covid»	Общее количество РИГК
Обучающая	333	411	744
Тестовая	111	137	248
Контрольная	111	137	248
Всего	555	685	1240

Основные параметры изображений, входящих в DataSetA: размер не менее 224×224 пикселей, 8-битная модель RGB, формат JPEG. На рис. 1 приведены примеры рентгеновских изображений грудной клетки: здорового пациента и пациента с признаками коронавирусной пневмонии и подтвержденным диагнозом COVID-19.

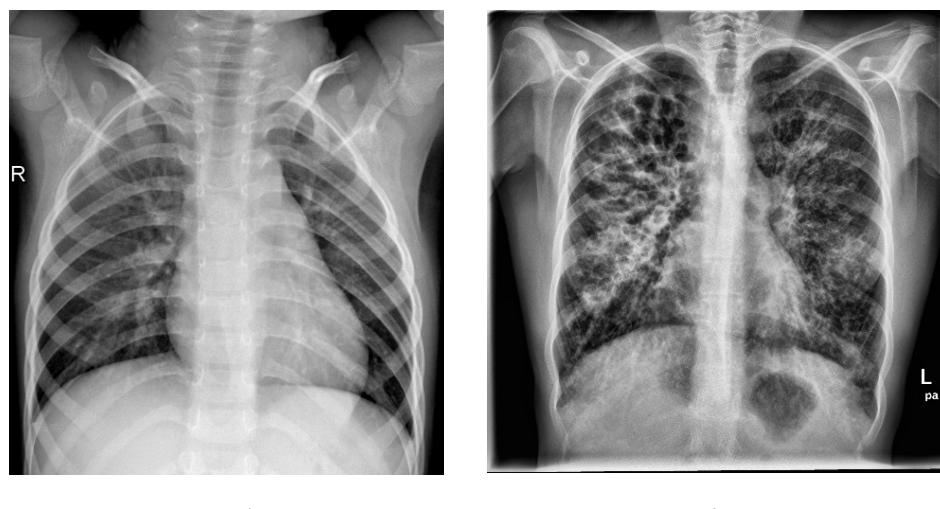


Рис. 1. Примеры РИГК:
 а – здорового пациента (класс «Normal»);
 б – пациента с признаками коронавирусной пневмонии (класс «Covid»)

Обучающая часть набора РИГК была подвергнута процедуре аугментации и нормализации. Аугментация значительно увеличила размер обучающей выборки и, что самое главное, повысила устойчивость модели к различным вариантам иискажениям, которые присутствуют в реальных РИГК.

2. Разработка архитектуры и оптимизация гиперпараметров модели.

На первом этапе исследования на РИГК DataSetA были обучены четыре хорошо известные модели, доказавшие свою эффективность при решении задач классификации изображений: Xception, Inceptionv3, VGG и ResNet50 (гиперпараметры моделей были установлены по умолчанию). Результаты классификации представлены в табл. 3.

Таблица 3

Метрики качества известных моделей при классификации РИГК DataSetA

Модель	Precision	Recall	F1-score	Accuracy
ResNet50	0,75	0,91	0,82	0,82
VGG	0,88	0,99	0,93	0,93
Xception	0,96	0,86	0,91	0,92
Inception v3	0,92	0,99	0,94	0,95

По результатам первого этапа исследования (табл. 3) был сделан вывод о недостаточной эффективности этих моделей для классификации РИГК с признаками COVID-19 пневмонии (во всяком случае, при их обучении на DataSetA и установке гиперпараметров по умолчанию).

Для повышения эффективности классификации разработана оригинальная модель, в основу архитектуры которой положена идея удвоения количества фильтров от слоя к слою с соответствующим уменьшением размера изображения за счет операций субдискретизации (MaxPooling). Нелинейность модели обеспечивается применением функции активации ReLU. Для предотвращения переобучения применены механизмы регуляризации: после сверточных слоев введены слои Dropout с коэффициентом 0,25, а перед финальным полносвязанным слоем внедрен слой Dropout с коэффициентом 0,5.

Такой подход позволил создать модель, способную извлекать высокоровневые абстрактные, мелкие и сложные для распознавания признаки изображений, характерные для РИГК. Архитектура разработанной модели, содержащей 14 слоев, представлена в табл. 4.

Для повышения эффективности и устойчивости обучения введена ранняя остановка (прекращение обучения при отсутствии улучшения валидационных метрик качества в течение 10 эпох) и экспоненциальное снижение скорости обучения на 50 % каждые 5 эпох при отсутствии прогресса в обучении. Установлены следующие гиперпараметры, обеспечивающие стабильное и эффективное обучение: скорость обучения – 0,001, размер пакета (batch size) – 32. После каждого сверточного слоя применена пакетная нормализация (batch-normalization) для стабилизации процесса обучения и ускорения сходимости.

Таблица 4

Архитектура оригинальной модели для классификации РИГК

Номер слоя	Тип слоя	Параметры слоя	Свойства слоя
1	Входной сверточный	32 фильтра с размечтом ядра 3×3 . Функция активации – ReLU	Выделяет базовые признаки на изображениях, такие как границы и контуры
2	Сверточный	64 фильтра с размечтом ядра 3×3 . Функция активации – ReLU	Выявляет более сложные признаки на изображении
3	Субдискретизирующий	Операция MaxPooling, ядро размером 2×2	Снижает размерность пространства признаков и улучшает вычислительную эффективность
4	Dropout	Коэффициент 0,25	Предотвращает переобучение модели за счет случайного обнуления 25 % входных данных на каждой эпохе обучения
5	Сверточный	128 фильтров с ядром 3×3 . Функция активации – ReLU	Выявляет более сложные и глубокие признаки на изображении
6	Субдискретизирующий	Операция MaxPooling, ядро 2×2	Снижает размерность пространства признаков и улучшает вычислительную эффективность модели
7	Dropout	Коэффициент 0,25	Предотвращает переобучение модели за счет случайного обнуления 25 % входных данных на каждой эпохе обучения
8	Сверточный	256 фильтров с ядром 3×3 . Функция активации – ReLU	Распознает еще более сложные и глубокие признаки изображений
9	Субдискретизирующий	Операция MaxPooling, ядро 2×2	Дополнительно снижает размерность пространства признаков и повышает устойчивость модели к вариативности данных
10	Dropout	Коэффициент 0,25	Улучшает способность модели к обобщению
11	Flatten	–	Преобразует многомерное пространство признаков в одномерный вектор
12	Полносвязный (Dense)	64 нейрона, функция активации ReLU	Извлекает высокоуровневые, абстрактные признаки изображений
13	Dropout	Коэффициент 0,5	Предотвращает переобучение модели за счет случайного обнуления 50 % входных данных на каждой эпохе обучения
14	Полносвязный (Dense)	1 нейрон, функция активации Sigmoid	Обеспечивает бинарную классификацию изображений

Установленные гиперпараметры обеспечили баланс между недообучением и переобучением модели.

3. Обучение и тестирование модели. При обучении модели в качестве функции потерь использована бинарная кросс-энтропия, для оптимизации выбран алгоритм адаптивной оптимизации Adam. Качество обучения оценивалось с применением стандартных метрик классификации [21].

Обучение модели проходило в течение 20 эпох. В процессе обучения модель корректировала свои веса, увеличивая значение Accuracy и уменьшая значение функции потерь Loss. На рис. 2 показаны графики изменения Accuracy и функции потерь Loss на обучающих (Training) и валидационных (Validation) данных в зависимости от номера эпохи.

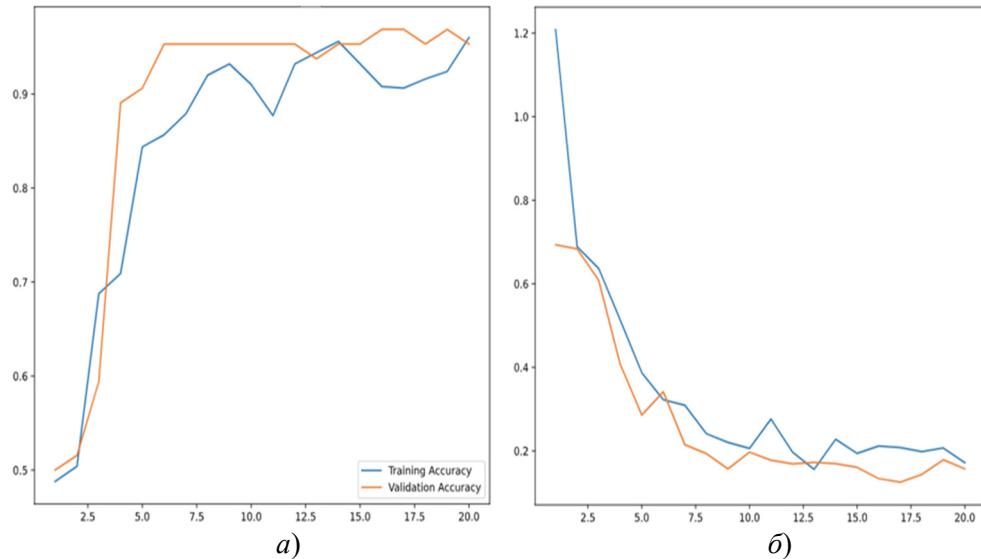


Рис. 2. Динамика изменения метрик Accuracy и Loss в процессе обучения модели:
а – Accuracy; б – Loss

Модель использовала стохастический градиентный спуск (SGD) для оптимизации весов, что позволило постепенно улучшать качество классификации на каждой эпохе. В процессе обучения было важно следить за тем, чтобы функция потерь Loss не начинала расти после достижения некоторого минимума, что свидетельствовало бы о переобучении модели.

В течение первых нескольких эпох обучения наблюдалось значительное снижение Loss и увеличение Accuracy, что характерно для начальной фазы обучения, когда модель быстро находит основные зависимости в данных. После 10-й эпохи процесс обучения начинает замедляться, значения функции потерь практически перестают уменьшаться, а модель постепенно достигает высокой сходимости, показывая достаточно стабильные значения Accuracy на валидационных данных. Такое поведение метрик Accuracy и Loss в процессе обучения свидетельствует о том, что модель смогла достаточно хорошо запомнить паттерны (признаки наличия/отсутствия COVID-19 пневмонии), содержащиеся в DataSetA, и достигла состояния, когда дальнейшее обучение практически не приводит к повышению качества классификации.

Таким образом, можно сделать вывод, что модель достигла высокого уровня сходимости и стабилизации метрик Accuracy и Loss после 10-й эпохи, что свидетельствует о ее эффективности и хорошей способности к обобщению без переобучения.

Сходимость соответствующих графиков Training и Validation друг к другу подтверждает корректность обучения модели: модель не переобучена, хорошо обобщает данные и готова к работе в реальных условиях.

Модель реализована в интегрированной среде разработки Visual Studio Code, предлагающей удобные инструменты для работы с кодом и обеспечивающей интеграцию с различными библиотеками (TensorFlow, PyTorch) и фреймворками. Для создания и управления изолированными виртуальными средами использованы средства пакета Miniconda.

Результаты и обсуждение

По результатам классификации РИГК тестовой части DataSetA были получены следующие значения метрик качества: Sensitivity (Recall) – 0,95, Specificity – 0,98, Precision – 0,97, Accuracy – 0,97, F1-score – 0,96, Loss – 0,01, которые превышают значения соответствующих метрик качества известных моделей глубокого обучения, полученные на первом этапе исследования (см. табл. 3). Близость значений метрик Precision и Recall свидетельствует о сбалансированности модели (ее способности одновременно минимизировать как ложноотрицательные, так и ложноположительные ошибки классификации).

Дополнительное тестирование обученной модели было проведено на новом наборе РИГК (DataSetB) из базы COVID-19 Radiography Database, доступной на виртуальной платформе Kaggle [22]. В DataSetB было включено 228 РИГК: 82 изображения класса «Covid» и 146 изображений класса «Normal». При классификации РИГК DataSetB были получены следующие значения метрик: Sensitivity (Recall), Specificity, Accuracy – 0,96; Precision – 0,93; Recall – 0,96; F1-score – 0,94. Значения соответствующих метрик при классификации РИГК DataSetA и DataSetB получились достаточно близкими, что доказывает репрезентативность, полноту и сбалансированность обучающих данных, а также эффективность проведенного обучения.

Сравнение результатов классификации РИГК DataSetA и DataSetB разработанной моделью с результатами других исследований в этой области (см. табл. 1) позволяет сделать вывод о достаточно высоком качестве классификации, соответствующем современному уровню.

Основываясь на значениях метрик качества врачебной классификации, приведенных в статье К. М. Арзамасова и соавторов [23], можно сделать вывод о том, что качество классификации РИГК разработанной оригинальной моделью сопоставимо с врачебным.

Заключение

Представлены основные результаты разработки оригинальной нейросетевой модели для бинарной классификации РИГК. Особенностью модели является компактная архитектура, содержащая 14 слоев. Классификатор не требует больших вычислительных мощностей при обучении. Несмотря на то, что модель была обучена на небольшом наборе изображений, она оказалась способной с высокой достоверностью выявлять признаки COVID-19 пневмоний.

Разработанный классификатор может быть использован в практической рентгенологии в качестве нейросетевого ассистента врача-рентгенолога.

Для обеспечения взаимодействия пользователя с обученной моделью было создано веб-приложение. Фронтенд разработан на JavaScript, бэкенд реализован на Python с использованием фреймворка Flask. Фронтенд и бэкенд связаны через REST API с передачей данных в формате JSON. Для защиты данных используется HTTPS и SSL-сертификат.

По результатам разработки нейросетевого классификатора РИГК получено свидетельство о государственной регистрации программы для ЭВМ [24].

Список литературы

1. Эсауленко Е. В., Александрович Ю. С., Бушманова А. Д. [и др.]. Вирусные пневмонии : учеб. пособие для врачей. СПб. : Изд-во СПбГПИМУ, 2021.
2. Кovidная пневмония // Медпортал. URL: <https://medportal.ru/enc/infection/coronavirus/kovidnaya-pnevmoniya/> (дата обращения: 20.05.2025).
3. Профилактика, диагностика и лечение новой коронавирусной инфекции (COVID19): временные методические рекомендации. Версия 18 (от 26.10.2023) / Министерство здравоохранения Российской Федерации. 250 с. URL: http://disuria.ru/_ld/13/1343_C19PDL261023N18.pdf (дата обращения: 20.05.2025).
4. Hemdan E. E., Shouman M. A., Karar M. E. COVIDX-NET: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-ray Images. URL: arXiv:2003.11055 (дата обращения: 20.05.2025).
5. Nishio M., Noguchi S., Matsuo H., Murakami T. Automatic Classification between COVID-19 Pneumonia, Non-COVID-19 Pneumonia, and The Healthy on Chest X-ray Image: Combination of Data Augmentation Methods // Sci. Rep. 2020. № 10 (1). P. 1–6.
6. Minaee S., Kafiehb R., Sonkac M. [et al.]. Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning // Med. Image Anal. 2020. № 65. P. 101794.
7. Wang L., Lin Z. Q., Wong A. COVID-NET: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images // Sci Rep. 2020. № 10 (1). P. 1–2.
8. Sethy P. K., Behera S. K., Ratha P. K., Biswas P. Detection of coronavirus disease (COVID-19) based on deep features and support vector machine. 2020. April // International Journal of Mathematical Engineering and Management Sciences. doi: 10.33888/IJMEMS.2020.5.4.052
9. Bassi P. R. A. S., Attux R. A Deep Convolutional Neural Network for COVID-19 Detection Using Chest X-Rays. URL: <https://arxiv.org/abs/2005.01578> (дата обращения: 20.05.2025).
10. Narin A., Kaya C., Pamuk Z. Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks // Pattern Anal Appl. 2021. May 9. P. 1–4.
11. Ефремцев В. Г., Ефремцев Н. Г., Тетерин Е. П. [и др.]. Классификация рентгеновских изображений грудной клетки больных вирусной пневмонией и COVID-19 с помощью нейронных сетей // Компьютерная оптика. 2021. Т. 45, № 1. С. 149–153.
12. Shelke A., Inamdar M., Shah V. [et al.]. Chest X-ray Classification Using Deep Learning for Automated COVID-19 Screening // SN Comput Sci. 2021. № 2 (4). P. 300. URL: <https://link.springer.com/article/10.1007/s42979-021-00695-5> (дата обращения: 20.05.2025).
13. Зеленина Л. И., Хаймина Л. Э., Деменкова Е. А. [и др.]. Сверточные нейронные сети в задаче классификации медицинских изображений // Современные научно-исследовательские технологии. 2021. № 9. С. 68–73.

14. Nigam B., Nigam A., Jain R. [et al.]. COVID-19: Automatic detection from X-ray images by utilizing deep learning methods // Expert Syst. Appl. 2021. № 176. P. 114883.
15. Щетинин Е. Ю. Обнаружение коронавирусной инфекции COVID-19 на основе анализа рентгеновских снимков грудной клетки методами глубокого обучения // Компьютерная оптика. 2022. Т. 46, № 6. С. 963–970.
16. Basma W. A., Salman H. M. A. A Convolutional Neural Network for Detecting COVID-19 from Chest X-ray Images // Iraqi Journal of Computer Communication Control and System Engineering. 2022. № 22 (3). P. 1–14. doi: 10.33103/uot.ijccce.22.3.1
17. Chow L. S., Tang G. S., Solihin M. I. [et al.]. Quantitative and qualitative analysis of 18 deep convolutional neural network (CNN) models with transfer learning to diagnose COVID-19 on chest X-ray (CXR) images // SN Comput. Sci. 2023. № 4 (2). P. 141.
18. Md. Harun Or Rashid, Minhaz M. H., Sarker A. [et al.]. COVID-19 Detection from Chest X-Ray Images Using Convolutional Neural Network Approach // Journal of Computer and Communications. 2023. Vol. 11, № 5.
19. Asif S., Qurrat-ul-Ain, Awais M. [et al.]. A Deep Ensemble Learning Framework for COVID-19 Detection in Chest X-ray Images // Network Modeling Analysis in Health Informatics and Bioinformatics. 2024. Vol. 13. P. 30.
20. Ghaderzadeh M., Farkhondeh A. Deep Learning in the Detection and Diagnosis of COVID-19 Using Radiology Modalities: A Systematic Review // Journal of Healthcare Engineering. 2021. P. 6677314. doi: 10.1155/2021/6677314
21. Захаренко Е. Метрики оценки качества моделей и анализ ошибок в машинном обучении. Подробное руководство. URL: https://habr.com/ru/users/egaoharu_kensei/ (дата обращения: 20.05.2025).
22. Kaggle. URL: <https://www.kaggle.com/> (дата обращения: 20.05.2025).
23. Арзамасов К. М., Семенов С. С., Кокина Д. Ю. [и др.]. Критерии применимости компьютерного зрения для профилактических исследований на примере рентгенографии и флюорографии органов грудной клетки // Медицинская физика. 2022. № 4. С. 56–63.
24. Свидетельство о государственной регистрации программы для ЭВМ № 2024616745. Программа для обнаружения признаков пневмонии, вызванной COVID-19, на рентгеновских снимках грудной клетки / Л. Ю. Кривоногов, И. С. Иномбоев ; опубл. 25.03.2024.

References

1. Esaulenko E.V., Alexandrovich Yu.S., Bushanova A.D. et. al. *Virusnye pnevmonii: ucheb. posobie dlya vrachej = Viral pneumonia: textbook. a manual for doctors*. Saint Petersburg: Izd-vo SPbGPMU, 2021.
2. Covid pneumonia. *Medportal = Medical portal*. (In Russ). Available at: <https://medportal.ru/enc/infection/coronavirus/kovidnaya-pnevmoniya/> (accessed 20.05.2025).
3. *Profilaktika, diagnostika i lechenie novoj koronavirusnoj infektsii (COVID19): vremennye metodicheskie rekomendatsii. Versiya 18 (ot 26.10.2023) = Prevention, diagnosis and treatment of novel coronavirus infection (COVID19): temporary guidelines. Version 18 (dated October 26, 2023)*. Ministry of Health of the Russian Federation. 250 p. (In Russ). Available at: http://disuria.ru/_ld/13/1343_C19PDL261023N18.pdf (accessed 20.05.2025).
4. Hemdan E.E., Shouman M.A., Karar M.E. *COVIDX-NET: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-ray Images*. Available at: arXiv:2003.11055 (accessed 20.05.2025).
5. Nishio M., Noguchi S., Matsuo H., Murakami T. Automatic Classification between COVID-19 Pneumonia, Non-COVID-19 Pneumonia, and The Healthy on Chest X-ray Image: Combination of Data Augmentation Methods. *Sci. Rep.* 2020;(10):1–6.
6. Minaee S., Kafiehb R., Sonkac M. et al. Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning. *Med. Image Anal.* 2020;(65):101794.

7. Wang L., Lin Z. Q., Wong A. COVID-NET: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images. *Sci Rep.* 2020;(10):1–2.
8. Sethy P.K., Behera S.K., Ratha P.K., Biswas P. Detection of coronavirus disease (COVID-19) based on deep features and support vector machine. 2020 April. *International Journal of Mathematical Engineering and Management Sciences*. doi: 10.33889/IJMENS.2020.5.4.052
9. Bassi P.R.A.S., Attux R. *A Deep Convolutional Neural Network for COVID-19 Detection Using Chest X-Rays*. Available at: <https://arxiv.org/abs/2005.01578> (accessed 20.05.2025).
10. Narin A., Kaya C., Pamuk Z. Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks. *Pattern Anal Appl.* 2021;May 9:1–4.
11. Efremtsev V.G., Efremtsev N.G., Teterin E.P. et al. Classification of chest X-ray images of patients with viral pneumonia and COVID-19 using neural networks. *Komp'yuternaya optika = Computer optics*. 2021;45(1):149–153. (In Russ)
12. Shelke A., Inamdar M., Shah V. et al. Chest X-ray Classification Using Deep Learning for Automated COVID-19 Screening. *SN Comput Sci.* 2021;(2):300. Available at: <https://link.springer.com/article/10.1007/s42979-021-00695-5> (accessed 20.05.2025).
13. Zelenina L.I., Khaimina L.E., Demenkova E.A. et al. Convolutional neural networks in the task of classifying medical images. *Sovremennye naukoemkie tekhnologii = Modern science-intensive technologies*. 2021;(9):68–73. (In Russ)
14. Nigam B., Nigam A., Jain R. et al. COVID-19: Automatic detection from X-ray images by utilizing deep learning methods. *Expert Syst. Appl.* 2021;(176):114883.
15. Shchetinin E.Y. Detection of coronavirus infection COVID-19 based on the analysis of chest X-rays by deep learning methods. *Komp'yuternaya optika = Computer optics*. 2022;46(6):963–970. (In Russ)
16. Basma W.A., Salman H.M.A. A Convolutional Neural Network for Detecting COVID-19 from Chest X-ray Images. *Iraqi Journal of Computer Communication Control and System Engineering*. 2022;22:1–14. doi: 10.33103/ujot.ijccce.22.3.1
17. Chow L.S., Tang G.S., Solihin M.I. et al. Quantitative and qualitative analysis of 18 deep convolutional neural network (CNN) models with transfer learning to diagnose COVID-19 on chest X-ray (CXR) images. *SN Comput. Sci.* 2023;(4):141.
18. Md. Harun Or Rashid, Minhaz M.H., Sarker A. et al. COVID-19 Detection from Chest X-Ray Images Using Convolutional Neural Network Approach. *Journal of Computer and Communications*. 2023;11(5).
19. Asif S., Qurrat-ul-Ain, Awais M. et al. A Deep Ensemble Learning Framework for COVID-19 Detection in Chest X-ray Images. *Network Modeling Analysis in Health Informatics and Bioinformatics*. 2024;13:30.
20. Ghaderzadeh M., Farkhondeh A. Deep Learning in the Detection and Diagnosis of COVID-19 Using Radiology Modalities: A Systematic Review. *Journal of Healthcare Engineering*. 2021;6677314. doi: 10.1155/2021/6677314
21. Zakharenko E. *Metriki otsenki kachestva modelej i analiz oshibok v mashinnom obuchении. Podrobnoe rukovodstvo = Metrics for evaluating model quality and error analysis in machine learning. Detailed guide*. (In Russ.). Available at: https://habr.com/ru/users/egaoharu_kensei/ (accessed 20.05.2025).
22. Kaggle. Available at: <https://www.kaggle.com/> (accessed 20.05.2025).
23. Arzamasov K.M., Semenov S.S., Kokina D.Yu. et al. Criteria for the applicability of computer vision for preventive research using the example of chest X-ray and fluorography. *Meditinskaya fizika = Medical Physics*. 2022;(4):56–63. (In Russ)
24. Svidetel'stvo o gosudarstvennoj registratsii programmy dlya EVM № 2024616745. Programma dlya obnaruzheniya priznakov pnevmonii, vyzvannoj COVID-19, na rentgenovskikh snimkakh grudnoj kletki = Certificate of state registration of the computer program № 2024616745. A program for detecting signs of pneumonia caused by COVID-19 on chest X-rays. L.Y. Krivonov, I.S. Inomboev; publ. 03/25/2024.

Информация об авторах / Information about the authors

Леонид Юрьевич Кривоногов

доктор технических наук, доцент,
профессор кафедры медицинской
кибернетики и информатики,
Пензенский государственный
университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: leonidkrivonogov@yandex.ru

Leonid Yu. Krivonogov

Doctor of technical sciences, associate
professor, professor of the sub-department
of medical cybernetics
and computer science,
Penza State University
(40 Krasnaya street, Penza, Russia)

Илхомджон Сулхиддинович Иномбоев

студент,
Пензенский государственный
университет
(Россия, г. Пенза, ул. Красная, 40)
E-mail: ilhomdzoninomboev@gmail.com

Ilhomjon S. Inomboev

Student,
Penza State University
(40 Krasnaya street, Penza, Russia)

Юлия Петровна Чебан

врач-рентгенолог рентгеновского
отделения,
Пензенская областная клиническая
больница имени Н. Н. Бурденко
(Россия, г. Пенза, ул. Лермонтова, 28)
E-mail: petrunina_julija@inbox.ru

Yulia P. Cheban

Radiologist of X-ray department,
Penza Regional Clinical Hospital
named after N.N. Burdenko
(28 Lermontova street, Penza, Russia)

Авторы заявляют об отсутствии конфликта интересов /
The authors declare no conflicts of interests.

Поступила в редакцию/Received 12.03.2025

Поступила после рецензирования/Revised 18.07.2025

Принята к публикации/Accepted 18.07.2025