

## ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ОБРАБОТКА ИНФОРМАЦИИ

УДК 004

*С.Н. Верзунов, [verzunov@hotmail.com](mailto:verzunov@hotmail.com)*

*Институт машиноведения и автоматизации НАН КР*

### ДИАГНОСТИКА РАЗЛИЧНЫХ ВИДОВ ПНЕВМОНИИ ПО РЕНТГЕНОВСКИМ СНИМКАМ ГРУДНОЙ КЛЕТКИ

Продолжающаяся вспышка и распространение вируса COVID-19 в 2020-2022 году послужили толчком для решения ряда биомедицинских проблем. Развитие алгоритмов машинного обучения предоставляет широкие возможности в области автоматизации решения такого рода задач. В настоящей работе рассматривается подробная классификация пневмонии на вирусную, бактериальную и вызванную туберкулезом. Всего выделяется 6 классов. В результате исследований было подтверждено, что рентгеновские снимки грудной клетки могут иметь большое значение для постановки диагноза пациентам с COVID-19 и также могут быть полезны для диагностики различных видов пневмонии, разработана архитектура нейронной сети для диагностики заболеваний легких. Разработан прототип мобильного приложения для диагностики различных видов пневмонии, который используется для тестирования и усовершенствования разработанной системы.

**Ключевые слова:** классификация изображений, нейронная сеть, CNN, различные виды пневмонии, мобильное приложение.

#### Введение

Внезапная вспышка и распространение вируса COVID-19 в 2020 году послужили толчком для решения ряда биомедицинских задач, в том числе проблем распознавания снимков и функциональной диагностики легких. Функциональная диагностика представляет собой раздел диагностики, содержанием которого являются объективная оценка, обнаружение отклонений и установление степени нарушений функции различных органов и физиологических систем организма на основе измерения физических, химических или иных объективных показателей их деятельности с помощью инструментальных или лабораторных методов исследования.

Развитие алгоритмов машинного обучения предоставляет широкие возможности в области автоматизации решения биомедицинских задач. Компьютерная обработка биомедицинских изображений повышает точность анализа изображений, снижает роль человеческого фактора при принятии решений, позволяет оценить эффективность применения терапии и в целом улучшает качество жизни людей. Активно развиваются биомедицинские исследования в области анализа и распознавания изображений, полученных при функциональной диагностике [1].

В [2] отмечено, что технологии, основанные на искусственном интеллекте (ИИ), включая машинное обучение, распознавание изображений и алгоритмы глубокого обучения, могут быть использованы для раннего обнаружения и диагностики инфекции COVID-19.

Описана алгоритмизация процесса распознавания состояний на основе специальных рентгеновских изображений в [3]. Предложен метод нейросетевого анализа. Для этого была реализована нейронная сеть, которая имеет возможность самообучаться. Использовались методы опорных векторов и дискриминантный анализ для сведения к минимуму вероятности ошибки экспертной системы.

Рассмотрены различные подходы машинного обучения в [4], используемые при прогнозировании распространения заболеваемости, и прогнозировании состояния пациентов при вирусе COVID-19. Отмечается, что в последние годы анализ медицинских изображений является одним из наиболее перспективных направлений исследования. Описываются наиболее широко известные алгоритмы для машинного обучения – случайный лес (Random Forest, RF) и машина опорных векторов (SVM); для глубокого обучения – сверточная нейронная сеть (CNN), длинная кратковременная память (LSTM),

генеративные состязательные сети (GAN), остаточная нейронная сеть (Residual Neuralnetwork, ResNet), автоенкодер. Также отмечается, что были использованы математические и статистические модели при оценке человеческих потерь, а также в прогнозировании общего количества смертей до определенного периода или конца пандемии.

В настоящей работе рассматривается подробная классификация пневмонии на вирусную, бактериальную и вызванную туберкулёзом. Так, выделяется 6 классов: COVID-19, норма, бактериальная пневмония, вирусная пневмония, туберкулёз и отдельный класс для заболеваний невыясненной природы, который мы для краткости назовем «затемнение легких». К сожалению, здесь также для большинства пациентов имеется только одномоментный набор рентгеновских снимков грудной клетки. Это ограничение приводит к тому, что оказывается невозможным определить, появились ли у пациентов рентгенологические особенности по мере прогрессирования болезни.

#### **Аппаратное и программное обеспечение исследований**

Для проведения вычислительных экспериментов по обучению нейронных сетей использовался суперкомпьютер, предоставленный в рамках договора о сотрудничестве между ИМА НАН КР и КРСУ им. Б.Н. Ельцина. Основные характеристики используемого программного и аппаратного обеспечения приведены в таблице 1.

Таблица 1 – Основные характеристики используемого аппаратного обеспечения

Операционная система	Ubuntu 18.04.5 LTS
Материнская плата	ASUSTeK COMPUTER INC. TUF Z270 MARK 2
Процессор	Intel(R) Core(TM) i7-7700K CPU @ 4.20GHz
Твердотельный накопитель	ATA ADATA SP580
Память	32880 Мб
Графические адаптеры (GPU)	2 X NVIDIA Corporation GP104 [GeForce GTX 1080]
Суммарная производительность	17.7 TFLOPS

Как видно из таблицы 1, основную вычислительную мощность суперкомпьютера обеспечивают два GPU NVIDIA GeForce GTX 1080, имеющих 2560 ядер CUDA каждая, работающих на частоте 1607 MHz в режиме SLI, что позволяет задействовать одновременно оба графических адаптера.

В качестве основного программного обеспечения вычислительного эксперимента использовался контейнер на основе официального Docker-образа фреймворка машинного обучения TensorFlow версии tensorflow:2.4.1-gpu-jupyter.

Для достижения максимальной производительности использовалась «зеркальная» стратегия распределения работы, в равной мере разделяющая текущую задачу между всеми GPU и обеспечивающая синхронизацию с помощью алгоритма All-Reduce [5]. Это позволяет в среднем примерно на 70% задействовать вычислительную мощность обоих графических адаптеров (рис. 1).

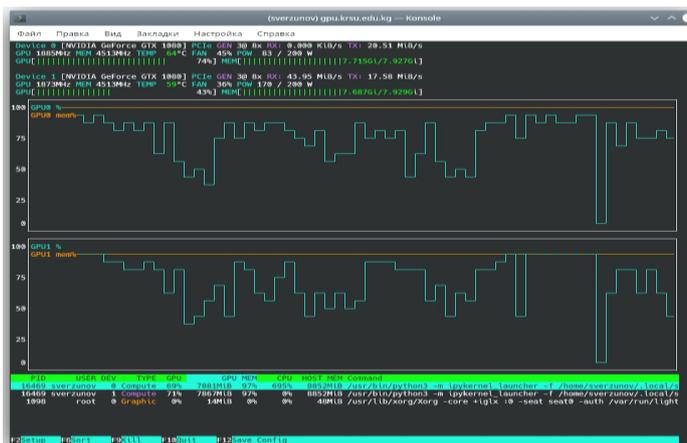


Рисунок 1 – График загрузки GPU во время обучения нейронной сети  
 Полностью используемая конфигурация контейнера показана в листинге ниже в формате docker-compose yaml-файла.

```
version: "2.4"
services:
  tensorflow:
    image: tensorflow/tensorflow:2.4.1-gpu-jupyter
    build:
      ./docker
    deploy:
      resources:
        reservations:
          devices:
            - driver: nvidia
              count: 2
              capabilities: [gpu]
    container_name: x-ray2
    ports:
      - 10000:8888
    volumes:
      - ./home:/home/sverzunov/
      - ./src:/tf
    user: sverzunov:sverzunov
```

Для получения необходимой информации о ходе обучения использовались также некоторые дополнительные библиотеки, такие, как, например, `numpy`, `matplotlib`, и другие. Полностью программная конфигурация в формате `Dockerfile`, использовавшаяся при обучении нейронных сетей, показана в листинге ниже.

Следует отметить, что проброс домашней директории пользователя в контейнере в папку на хост-системе позволил сохранять между сеансами важные настройки библиотеки `matplotlib` и используемой облачной интерактивной среды разработки `Jupyter`.

```
FROM tensorflow/tensorflow:2.4.1-gpu-jupyter
RUN apt-get update
RUN apt install -y python3-pip
RUN python3 -m pip install --upgrade pip
RUN python3 -m pip install \
numpy \
pandas \
matplotlib
RUN groupadd -f sverzunov --gid 1000
RUN id -u sverzunov >/dev/null 2>&1 || useradd -G sverzunov --uid
1000 sverzunov
```

```
RUN mkdir -p /home/sverzunov
RUN chown -R sverzunov:sverzunov /home/sverzunov
```

Таким образом, описанная здесь программно-аппаратная конфигурация позволила в большей степени задействовать все имеющиеся в нашем распоряжении вычислительные ресурсы и достичь скорости обучения до 350 изображений в секунду при использовании, например, предварительно обученной сверточной нейронной сети EfficientNetB2, что на порядок больше того, что можно было бы достичь, если бы использовались только вычислительные мощности CPU.

### Исходные данные

В настоящей работе использовались четыре общедоступные базы данных рентгеновских снимков грудной клетки:

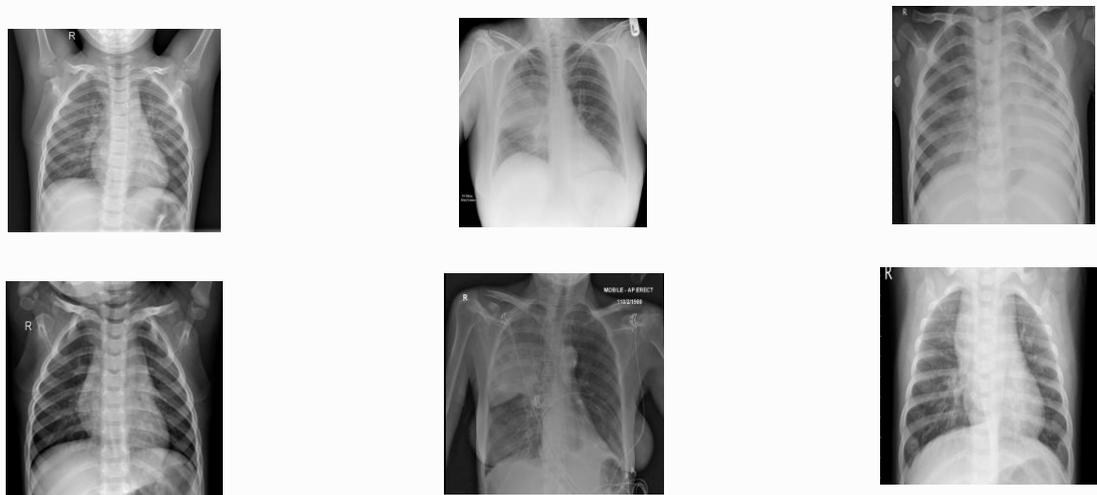
1. Chest X-Ray Images (Pneumonia) [6].
2. COVID-19 image data collection [7].
3. COVID-19\_Radiography\_Dataset [8].
4. TB\_Chest\_Radiography\_Database [9].

Набор данных [6] состоит из рентгеновских снимков грудной клетки здоровых людей и пациентов с бактериальной и вирусной пневмонией. Всего имеется 5856 рентгенограмм в передней прямой проекции, примерно 2/3 из них принадлежит пациентам, больным пневмонией, приблизительно поровну вирусной и бактериальной, а остальная часть здоровым пациентам.

Набор [7] содержит 468 рентгеновских снимков грудной клетки пациентов с COVID-19, 38 снимков с вирусной пневмонией, 46 снимков с бактериальной пневмонией, 26 снимков с грибковой пневмонией, 9 снимков с пневмонией другого типа и 59 изображений другого типа (рис. 2).

Набор [8] содержит 3616 рентгеновских снимков грудной клетки пациентов с COVID-19, 1345 снимков с вирусной пневмонией, 10192 снимка грудной клетки здоровых людей и 6012 снимков с затемнениями на легких, вызванными неизвестными причинами.

Набор [9] содержит 700 рентгеновских снимков пациентов с туберкулезом и 3500 снимков грудной клетки здоровых людей. Для классификации по двум классам из первого набора был выбран 191 рентгеновский снимок грудной клетки здоровых людей в передней прямой проекции (рис. 2а), а из второго набора 191 снимок грудной клетки пациентов, больных COVID-19 (рис. 2б), в передней и задней прямой проекции с дополнением данных путем случайного поворота на величину до 15° и случайного отражения в горизонтальной плоскости.



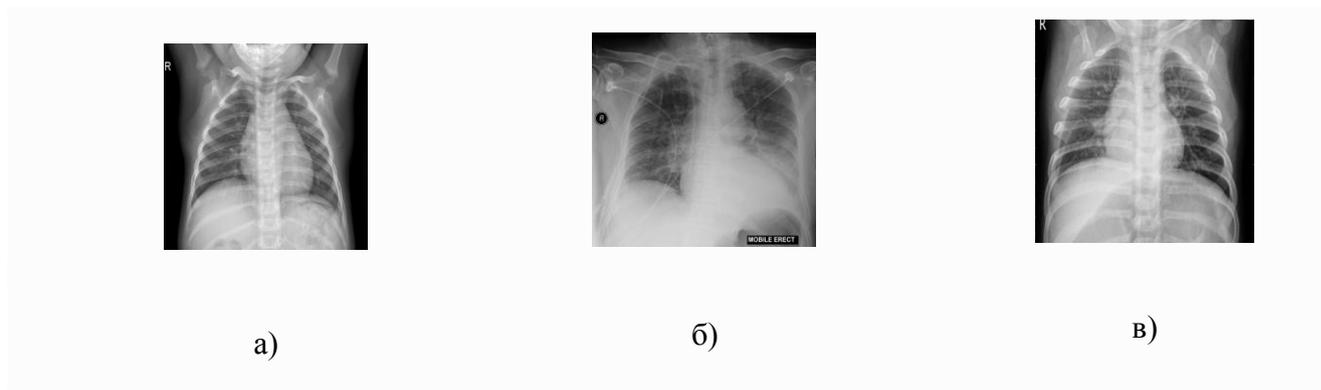


Рисунок 2 – Наборы данных:

а) Chest X-Ray Images (норма); б) COVID-19 image data collection (бактериальная пневмония); в) COVID-19\_Radiography\_Dataset (вирусная пневмония)

Дополнение отражением необходимо, так как в данных из первого набора присутствуют снимки только в передней проекции, во втором наборе как в передней, так и в задней проекции, а небольшой поворот изображения часто встречается при вводе изображения с помощью сканера или камеры.

Для классификации по 6 классам из всех вышеперечисленных наборов данных были выбраны 3616 рентгеновских снимков пациентов с COVID-19, 1345 снимков с вирусной пневмонией, 2780 снимков с бактериальной пневмонией, 6012 снимков с затемнением легких с невыясненной причиной, 700 снимков с туберкулезом и 10192 снимка грудной клетки здоровых людей, всего 27645 изображений (рис. 3).

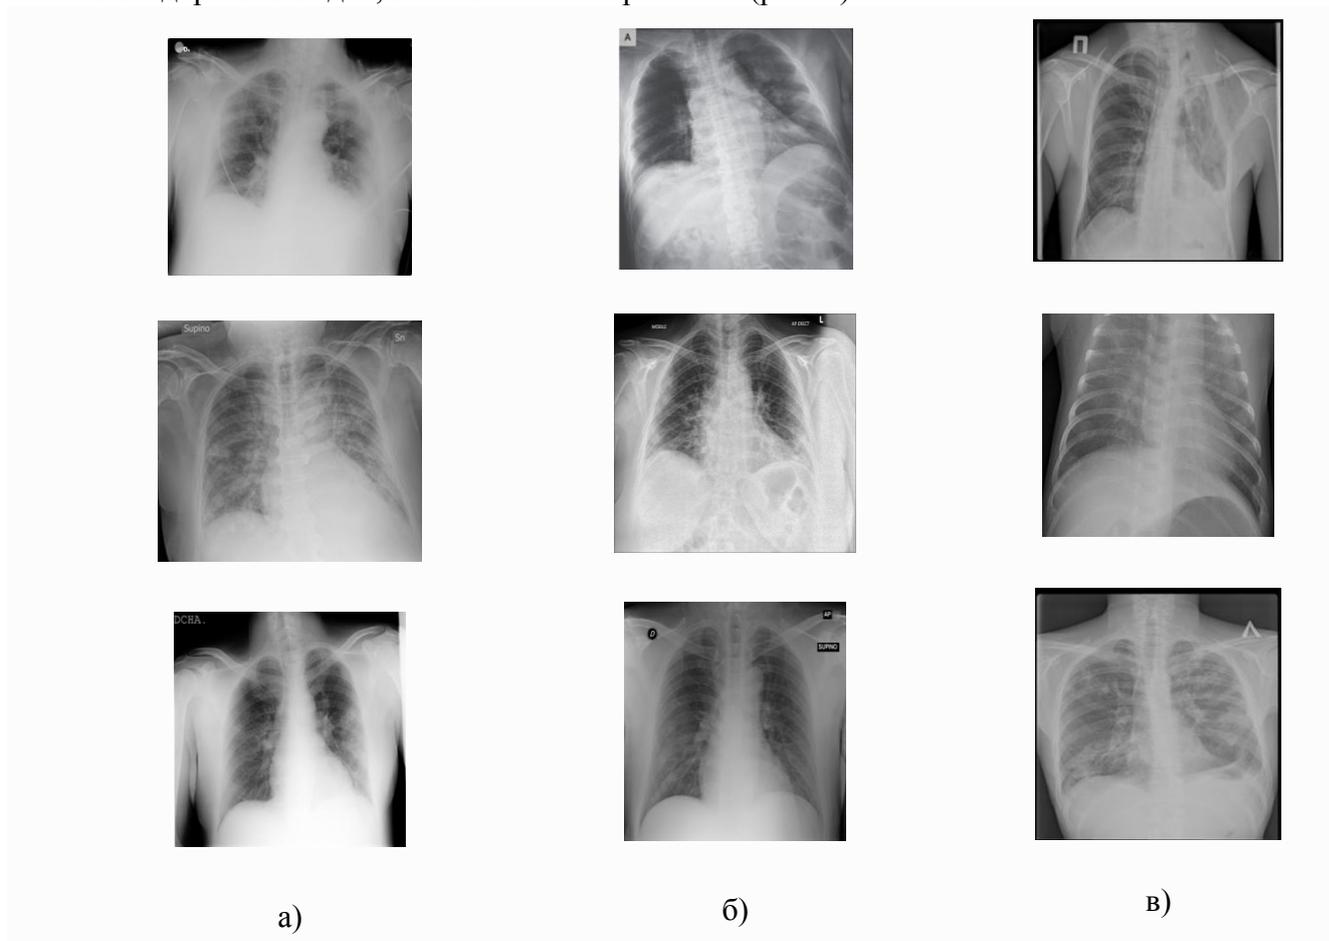


Рисунок 3 – Наборы данных: а) COVID-19\_Radiography\_Dataset (COVID-19); б) COVID-19\_Radiography\_Dataset (затемнение легких); в) TB\_Chest\_Radiography\_Database (туберкулез)

### Разработка архитектуры нейронной сети

В используемых здесь архитектурах предварительно обученных сверточных сетей последний слой с настраиваемыми весами по-прежнему является полносвязным слоем. Этот полносвязный слой, как и в работе [10], был заменен новой последовательностью слоев, состоящей теперь из слоя выбора среднего значения из соседних по всем каналам (слоя глобального пуллинга), для согласования размеров тензоров на выходе предыдущего слоя с входом последующего полносвязного слоя, состоящего из 128 нейронов, слоя прореживания с вероятностью 0,5 и выходного слоя из 6 нейронов, так как классификация производится по шести классам. Сравнение результатов приведено в таблице 2.

Сравнение убедительно свидетельствует о том, что обученные до достижения максимальной точности на протяжении 5 эпох нейронные сети на основе предварительно обученных CNN EfficientNetB3 и ResNet152 достигли наилучшего результата, чем 28 других моделей с точки зрения точности классификации и разных соотношений объема данных для обучения и проверки.

Таблица 2 – Результаты вычислительного эксперимента по диагностике различных видов пневмонии по рентгеновским снимкам грудной клетки

№	Модели	Точность, %	
		Обучающие данные 80%	Обучающие данные 50%
	DenseNet121	65	66
	DenseNet169	56	62
	DenseNet201	67	69
	EfficientNetB0	79	80
	EfficientNetB1	82	83
	EfficientNetB2	82	80
	EfficientNetB3	83	82
	EfficientNetB4	82	80
	EfficientNetB5	82	82
	EfficientNetB6	82	81
	EfficientNetB7	83	81
	InceptionResNetV2	41	41
	InceptionV3	41	41
	MobileNet	67	69
	MobileNetV2	68	67
	MobileNetV3Large	81	81
	MobileNetV3Small	80	77
	NASNetLarge	63	63
	NASNetMobile	60	60
	ResNet101	82	81
	ResNet101V2	41	41
	ResNet152	82	83
	ResNet152V2	41	41
	ResNet50	80	82
	ResNet50V2	41	41
	VGG16	82	79
	VGG19	82	78
	Xception	41	61

Так как предварительно обученная сверточная нейронная сеть EfficientNetB3 занимает меньший объем памяти, всего 48 MB, по сравнению 232 MB у ResNet152, для практического применения, в частности в мобильных приложениях, мы рекомендуем использовать именно эту сеть. Таким образом, архитектура сети имеет следующий вид, показанный в табл. 3.

Таблица 3 – Архитектура нейронной сети на основе CNN EfficientNetB3

Layer (type)	Output Shape	Param #
efficientnetb3 (Functional)	(None, 7, 7, 1536)	10783535
global_average_pooling2d_4 (	(None, 1536)	0
dense_8 (Dense)	(None, 128)	196736
dropout_4 (Dropout)	(None, 128)	0
dense_9 (Dense)	(None, 6)	774

Сверточная основа EfficientNetB3 имеет 10 783 535 параметров, что представляет собой достаточно большое число. Классификатор, добавленный сверху, имеет около 200 тысяч параметров. Поэтому перед обучением нейронной сети очень важно заморозить сверточную основу. Замораживание одного или нескольких слоев предотвращает изменение весовых коэффициентов в них в процессе обучения.

Если этого не сделать, тогда представления, прежде изученные сверточной основой, изменятся в процессе обучения на новых данных. Так как слои Dense сверху инициализируются случайными значениями, в сети могут произойти существенные изменения весов, фактически разрушив представления, полученные ранее.

На рисунке 4 показано изменение точности классификации на проверочном наборе данных в процессе обучения на протяжении 200 эпох. Как можно видеть из рисунка, обучая сеть на протяжении 97 эпох, можно достичь точности почти 87% на этапе проверки за счет тонкой настройки количества эпох обучения сети.

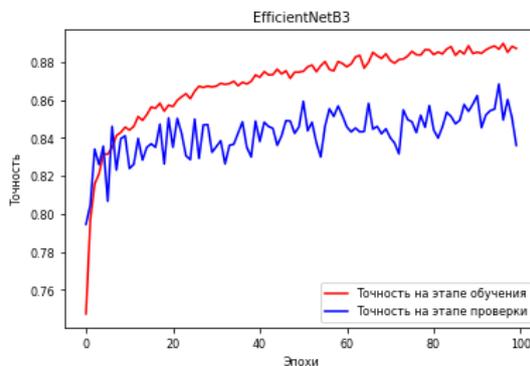


Рисунок 4 – Точность классификации на этапе обучения и проверки нейронной сети на основе предварительно обученной основы EfficientNetB3

Результаты, полученные по методу интегрированных градиентов и показанные на рисунке 5, дают представление об участках изображения, использующихся нейронной сетью для классификации изображений.

Для построения показанных на этом рисунке визуализаций интегрированного градиента использовались пиксели с уровнем значений использования сетью от 20 до 80% и нейронная сеть на базе сверточной основы EfficientNetB3.

Сеть сначала изучила внешние края и текстуру, а затем более абстрактные свойства изображений на высоких уровнях абстракции, что, на наш взгляд, привело к нахождению отличительных особенностей, эффективных для классификации рентгеновских снимков.

Для практической проверки разработанной части СИИ был подготовлен прототип мобильного приложения для операционной системы Android с помощью языка JAVA на базе фреймворка TensorFlow Lite, предоставляющего набор инструментов,

обеспечивающих реализацию машинного обучения на различных устройствах, позволяя использовать нейронные сети на мобильных, встроенных устройствах и устройствах Интернета вещей. Ключевыми особенностями этого фреймворка являются следующие:

1. Оптимизация для работы на мобильных и встроенных устройствах.
2. Поддержка нескольких платформ, включая устройства на базе Android и iOS , Linux и микроконтроллеров, например ESP32.
3. Поддержка разнообразных языков, включая Java, Swift, Objective-C, C ++ и Python.
4. Высокая производительность за счет использования доступного аппаратного ускорения.
5. Подробная документация и большое количество примеров для часто встречающихся задач машинного обучения.

Разработанные выше нейронные сети были конвертированы в специальный переносимый формат, принятый в библиотеке TensorFlow Lite, так называемый FlatBuffers, и сохранены в файле с расширением tflite. Этот формат дает несколько преимуществ по сравнению с форматом, принятым в библиотеке Keras, таких, как уменьшенный размер (что важно в мобильных приложениях), и более быстрый доступ, который осуществляется напрямую, без дополнительного этапа синтаксического анализа и распаковки, что позволяет СИИ эффективно работать на переносных устройствах с ограниченными вычислительными ресурсами и ресурсами памяти.

Полученные файлы в формате TensorFlow Lite дополнительно включают метаданные, содержащие описание нейронной сети, используемых ее классах и машиночитаемые данные для автоматического создания конвейеров предварительной и постобработки во время работы на устройстве.

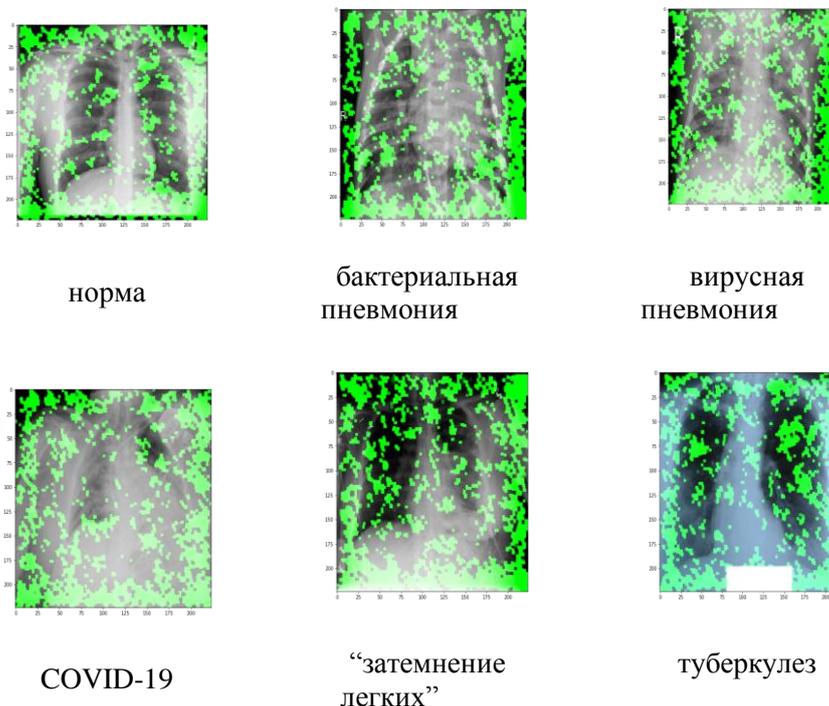


Рисунок 5 – Интерпретация результатов классификации различных изображений, показывающая, какие части изображения используются для классификации

Разработанный прототип мобильного приложения реализует такие функции, как (рис. 4):

1. Классификация изображения.
2. Отображение сведений о режиме работы нейронной сети.
3. Выбор количества потоков, используемых для работы нейронной сети.

4. Выбор используемой для классификации нейронной сети (DenseNet169 или EfficientNetB3).
5. Выбор используемого для работы нейронной сети устройства (CPU или GPU).

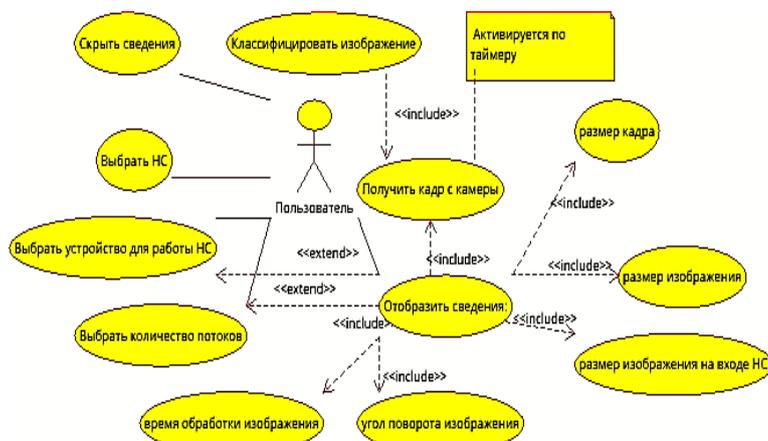


Рисунок 4 – Варианты использования прототипа программных средств

Через определенные промежутки времени, зависящие от времени обработки изображения, приложение получает “сырые” кадры с камеры. Нейронная сеть выполняет классификацию изображения по двум или шести классам в зависимости от выбранной модели сети. Пользователь может узнать распознанный сетью класс изображения, скрыть или отобразить дополнительные сведения о работе приложения, такие, как размер кадра; размер и угол поворота изображения, используемого сетью; время обработки изображения; количество используемых потоков процессора. Дополнительные сведения могут быть использованы для отладки программных средств (рис. 5).

Кроме того, пользователь может выбрать используемую для классификации нейронную сеть для диагностики по двум или шести классам, количество потребляемых потоков процессора, а также прилагаемое нейронной сетью для работы устройство: CPU или GPU. В дальнейшем планируется дополнить разработанную программу базой данных изображений, присланных пользователями, что позволит улучшить точность работы СИИ.

### Выводы

Таким образом, в результате исследований было подтверждено, что рентгеновские снимки грудной клетки могут иметь большое значение для постановки диагноза пациентам с COVID-19 и также могут быть полезны для диагностики различных видов пневмонии. Были собраны и проанализированы имеющиеся в сети Интернет рентгеновские снимки для диагностики COVID-19. Выполнен обзор и анализ литературы в области диагностики коронавирусной инфекции. Сформулированы критерии успешного решения задачи диагностики коронавирусной инфекции по рентгеновским снимкам в виде 6 характеристик для сравнения результатов обучения глубоких нейронных сетей.

Выполнена предварительная подготовка найденных изображений для построения нейросетевого классификатора на базе предварительно обученных сверточных нейронных сетей, выделены уникальные рентгеновские снимки грудной клетки по каждому классу: 10200, 1345, 2538, 3616, 700, 6012. В результате анализа изображений сформулирована задача диагностики коронавирусной инфекции как задача бинарной (COVID-19, норма) и многоклассовой классификации изображений грудной клетки по 6 классам: норма, вирусная пневмония, бактериальная пневмония, COVID-19, туберкулез, неуточненное заболевание легких. Разработаны и протестированы архитектуры на базе предварительно обученных сверточных нейронных сетей для дифференциальной диагностики коронавирусной инфекции и различных видов пневмонии. Выполнена регуляризация и настройка гиперпараметров предлагаемой нейронной сети: параметров прореживания, количества слоев, числа нейронов на слой, шага обучения оптимизатора. В результате

найлены наиболее оптимальные настройки нейронной сети. Разработан прототип мобильного приложения для диагностики различных видов пневмонии, который используется для тестирования и усовершенствования разработанной СИИ.



Рисунок 5 – Интерфейс и примеры диагностики различных заболеваний с помощью разработанного прототипа программных средств

### Литература

1. Яковлев, В. О. Анализ современного состояния исследований в области распознавания снимков функциональной диагностики легких / В. О. Яковлев // Мавлютовские чтения: Материалы XV Всероссийской молодежной научной конференции: в 7 томах, Уфа, 26–28 октября 2021

- года. – Уфа: Уфимский государственный авиационный технический университет, 2021. – С. 290–301.
2. Макаров В.В., Блатова Т.А., Ворошилова Е.Ю. Ускоренное развитие информационных технологий в период пандемии // Экономика и качество систем связи. 2021. №2 (20). URL: <https://cyberleninka.ru/article/n/uskorennoe-razvitie-informatsionnyh-tehnologiy-v-period-pandemii> (дата обращения: 18.07.2021).
  3. Васильченко Владислав Алексеевич, Бурковский Виктор Леонидович, Данилов Александр Дмитриевич Алгоритмизация процесса распознавания состояний физиологических объектов на основе специальных рентгеновских изображений КО.–2019.–№2.–URL: <https://cyberleninka.ru/article/n/algoritmizatsiya-protssessa-raspoznavaniya-sostoyaniy-fiziologicheskikh-obektov-na-osnove-spetsialnyh-rentgenovskih-izobrazheniy> (дата обращения: 18.07.2021).
  4. Хаджибаев Абдухаким Муминович, Адылова Фатима Туйчиевна, Касимов Хамит Махмудович, Шарипова Висолат Хамзаевна, Исхаков Нурбек Баркамоллович. Роль искусственного интеллекта в прогнозировании проблем COVID-19: аналитический обзор // Вестник экстренной медицины. –2020. – №4. URL: <https://cyberleninka.ru/article/n/rol-iskusstvennogo-intellekta-v-prognozirovanii-problem-covid-19-analiticheskiy-obzor> (дата о обращения: 18.07.2021).
  5. [https://www.tensorflow.org/api\\_docs/python/tf/distribute/MirroredStrategy](https://www.tensorflow.org/api_docs/python/tf/distribute/MirroredStrategy) (дата обращения: 18.07.2021)
  6. Daniel S. Kermany et all, Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning, Cell, Volume 172, Issue 5, 2018, Pages 1122-1131.e9, ISSN 0092-8674, <https://doi.org/10.1016/j.cell.2018.02.010>.
  7. COVID-19 Image Data Collection: Prospective Predictions Are the Future Joseph Paul Cohen and Paul Morrison and Lan Dao and Karsten Roth and Tim Q Duong and Marzyeh Ghassemi arXiv:2006.11988, <https://github.com/ieee8023/covid-chestxray-dataset>, 2020
  8. Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Kashem, S.B.A., Islam, M.T., Maadeed, S.A., Zughaier, S.M., Khan, M.S. and Chowdhury, M.E., 2020. Exploring the Effect of Image Enhancement Techniques on COVID-19 Detection using Chest X-ray Images
  9. Tawsifur Rahman, Amith Khandakar, Muhammad A. Kadir, Khandaker R. Islam, Khandaker F. Islam, Zaid B. Mahub, Mohamed Arselene Ayari, Muhammad E. H. Chowdhury. (2020) "Reliable Tuberculosis Detection using Chest X-ray with Deep Learning, Segmentation and Visualization". IEEE Access, Vol. 8, pp 191586 - 191601. DOI. 10.1109/ACCESS.2020.3031384
  10. Верзунов, С. Н. Сравнение глубоких нейронных сетей на основе различных предварительно обученных CNN для диагностики COVID-19 по рентгеновским снимкам / С. Н. Верзунов, Х. А. Раимжанов // Проблемы автоматизации и управления. – 2021. – № 1(40). – С. 12–25.