

УДК 004.89

С.Н. Верзунов¹, Х.А. Раимжанов²

¹Институт машиноведения и автоматизации НАН КР, Бишкек, Кыргызстан

²Кыргызско-Российский славянский университет, Бишкек, Кыргызстан

E-mail: verzunov@hotmail.com, halimjonraimjanov@gmail.com

СРАВНЕНИЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ НА ОСНОВЕ РАЗЛИЧНЫХ ПРЕДВАРИТЕЛЬНО ОБУЧЕННЫХ CNN ДЛЯ ДИАГНОСТИКИ COVID-19 ПО РЕНТГЕНОВСКИМ СНИМКАМ

В результате клинических исследований было обнаружено, что рентгеновские снимки грудной клетки могут иметь большое значение для оценки пациентов с COVID-19, особенно для решения проблемы недостаточной пропускной способности служб скорой помощи и ковидных стационаров. В настоящее время методы глубокого обучения играют доминирующую роль в создании высокопроизводительных классификаторов при обнаружении этого заболевания с помощью рентгеновских лучей грудной клетки. Учитывая, что для уже было разработано много новых моделей на основе нейронных сетей, цель этого исследования – изучить различные варианты предварительно обученных сверточных нейронных сетей для диагностики COVID-19 с использованием рентгеновских снимков грудной клетки и сравнить их другими моделями.

Ключевые слова: COVID-19, глубокое обучение, CNN, предварительно обученные сверточные сети.

Введение

После вспышки коронавирусной инфекции COVID-19 и ее объявления ВОЗ пандемией в марте 2020 года во всем мире были приняты беспрецедентные меры для сдерживания распространения болезни. При этом было доказано, что одним из ключевых факторов сдерживания болезни является быстрая и точная идентификация инфицированных пациентов, их адекватное лечение и изоляция от остального населения [1]. В настоящее время полимеразная цепная реакция (ПЦР) с обратной транскрипцией остается основным диагностическим инструментом, но роль рентгенографических методов исследования грудной клетки как дополнительных методов диагностики или даже надежной альтернативы получает все большее значение [2]. Объясняется это тем, что получение результатов ПЦР-теста может занять несколько дней, напротив информация, полученная при рентгенографическом исследовании, может быть незамедлительно использована для быстрой диагностики при сравнительно небольших затратах.

Тем не менее интерпретация рентгеновских снимков затруднительна, так как для того, чтобы обнаруживать тонкие визуальные особенности, присутствующие на изображениях, требуется достаточно высокая квалификация врачебного персонала. Напротив, система искусственного интеллекта (СИИ) может обнаруживать закономерности на рентгенограммах грудной клетки, обычно не распознающиеся врачами-радиологами, и в различных изданиях [3, 4, 5] было опубликовано множество исследований о новых разработках моделей СИИ с использованием сверточных нейронных сетей (convolutional neural network, CNN) с целью дифференцирования COVID-19 от других заболеваний с использованием общедоступных баз данных рентгеновских снимков грудной клетки. Как показано в этих работах, СИИ на основе технологий глубокого обучения позволила бы улучшить возможности рентгенографии с точки зрения распознавания типичных признаков COVID-19 и отделения ее от других типов пневмонии и, кроме того, могло бы ускорить диагностику больных и улучшить степень

определения риска тяжелого течения болезни в случаях с неопределенными результатами при отсутствии других диагностических методов.

Ранее разными авторами уже предпринимались попытки разработать СИИ для этой цели. Например, сеть Bayes-SqueezeNet [6] на основе метода байесовской оптимизации была использована для классификации рентгеновских снимков, разделенных на 3 класса: норма, вирусная пневмония и COVID-19. Благодаря широко известному методу расширения данных авторам удалось частично решить проблему переобучения сети на небольшом объеме данных.

СИИ CoroNet [7] также была разработана для обнаружения инфекции COVID-19 по рентгеновским снимкам грудной клетки. Эта модель основана на предварительно обученной CNN Xception с добавлением слоя прореживания и двух полносвязных слоев в конце. Сеть применялась для классификации по 3 классам (COVID-19, пневмония и норма, а также для классификации по 4 классам (COVID-19, бактериальная пневмония, вирусная пневмония и норма).

СИИ CovidGAN [8] с использованием генеративной состязательной сети была построена на основе предварительно обученной CNN VGG-16, дополненной четырьмя настраиваемыми сверточными слоями в конце и выбора среднего значения из соседних, за которым следовал полносвязный слой с 64 нейронами и слой прореживания с вероятностью 0.5 в конце. Также авторами была использована генеративно-состязательная сеть для создания синтетических рентгеновских изображений грудной клетки с целью расширения имеющегося объема данных и повышения эффективности классификации.

СИИ DarkCovidNet [9], основанная на модели DarkNet [10], является еще одной моделью CNN, предложенной для обнаружения COVID-19 с помощью рентгеновских снимков грудной клетки. DarkCovidNet состоит из меньшего, по сравнению с DarkNet количества слоев, и постепенно увеличивающихся фильтров выбора максимального значения из соседних. Эта СИИ была протестирована на 2 классах (COVID-19 и норма) и 3 классах (COVID-19, норма и пневмония).

В работе [11] были реализованы VGG-19, MobileNet-v2, Inception, Xception и Inception ResNet-v2, а в работе [12] сети AlexNet, GoogLeNet, and SqueezeNet, в качестве предварительно обученных CNN для обнаружения COVID-19 по рентгеновским снимкам. Эти СИИ были использованы для классификации на 2 и 3 класса с помощью наборов данных, состоящих из изображений COVID-19, бактериальной пневмонии, вирусной пневмонии и нормы.

Постановка задачи

Целью настоящего исследования является проверка того, можно ли построить надежный классификатор на основе технологий глубокого обучения с помощью предварительно обученной глубокой сверточной нейронной сети, дообученной на сравнительно небольшом объеме данных, а также сравнить различные варианты предварительно обученных нейронных сетей на базе: DenseNet[13], EfficientNet[14], InceptionResNetV2[15], InceptionV3[16], MobileNet[17], MobileNetV2[18], MobileNetV3[19], NASNet[20], ResNet[21], ResNetV2[22], VGG[23], Xception[24].

Эти предварительно обученные CNN выбраны по той причине, что они все входят в состав свободно распространяемого фреймворка Keras [25]. Классификация выполнялась по двум классам COVID-19 и норма, исходя из имеющихся в настоящее время в распоряжении авторов объема исходных данных для обучения. При этом, остальные возможные классы, например, пневмония, туберкулёз и т.д. в настоящем исследовании не учитываются.

Предварительно обученные сверточные нейронные сети

Основные параметры некоторых используемых предварительно обученных нейронных сетей приведены в табл. 1. Полностью гиперпараметры всех используемых нейронных сетей даны в работах [13-24]. В предварительно обученных сетях последний слой с настраиваемыми весами является полносвязным слоем. Этот полносвязный слой был заменен новой последовательностью слоев, состоящей из слоя выбора максимального значения из соседних размером 4x4, промежуточного слоя для согласования размеров тензоров на выходе предыдущего слоя с входом последующего, полносвязного слоя, состоящего из 128 нейронов, слоя прореживания с вероятностью 0.6 и выходного слоя из 2 нейронов, так как классификация производится по двум классам.

Таблица 1. Основные параметры предварительно обученных CNN

№ п.п.	Модель	Размер	Топ-1 по точности	Топ-5 по точности	Количество параметров	Глубина
1.	Xception	88 MB	0.790	0.945	22,910,480	126
2.	VGG16	528 MB	0.713	0.901	138,357,544	23
3.	VGG19	549 MB	0.713	0.900	143,667,240	26
4.	ResNet50	98 MB	0.749	0.921	25,636,712	-
5.	ResNet101	171 MB	0.764	0.928	44,707,176	-
6.	ResNet152	232 MB	0.766	0.931	60,419,944	-
7.	ResNet50V2	98 MB	0.760	0.930	25,613,800	-
8.	ResNet101V2	171 MB	0.772	0.938	44,675,560	-
9.	ResNet152V2	232 MB	0.780	0.942	60,380,648	-
10.	InceptionV3	92 MB	0.779	0.937	23,851,784	159
11.	InceptionResNetV2	215 MB	0.803	0.953	55,873,736	572
12.	MobileNet	16 MB	0.704	0.895	4,253,864	88
13.	MobileNetV2	14 MB	0.713	0.901	3,538,984	88
14.	DenseNet121	33 MB	0.750	0.923	8,062,504	121
15.	DenseNet169	57 MB	0.762	0.932	14,307,880	169
16.	DenseNet201	80 MB	0.773	0.936	20,242,984	201
17.	NASNetMobile	23 MB	0.744	0.919	5,326,716	-
18.	NASNetLarge	343 MB	0.825	0.960	88,949,818	-
19.	EfficientNetB0	29 MB	-	-	5,330,571	-
20.	EfficientNetB1	31 MB	-	-	7,856,239	-
21.	EfficientNetB2	36 MB	-	-	9,177,569	-
22.	EfficientNetB3	48 MB	-	-	12,320,535	-
23.	EfficientNetB4	75 MB	-	-	19,466,823	-
24.	EfficientNetB5	118 MB	-	-	30,562,527	-
25.	EfficientNetB6	166 MB	-	-	43,265,143	-
26.	EfficientNetB7	256 MB	-	-	66,658,687	-

Исходные рентгеновские снимки грудной клетки были приведены к формату RGB и преобразованы таким образом, чтобы их размер соответствовал входному размеру предварительно обученных CNN – 224x224 точек. Для дополнительного обучения нейросетевых классификаторов использовался оптимизатор Adam [26], основанный на стохастическом градиентном спуске и адаптивной оценке моментов первого и второго порядков с параметром начальной скорости обучения $L_r=0.001$ и постоянной скоростью уменьшения до нуля на протяжении всего процесса обучения эпох, с размером пакетов при обучении, равном 10 и экспоненциальной скорости затухания для 1-го момента $\beta_1 = 0.9$, для


2-го момента $\beta_2=0.999$ и константой численной стабильности $\varepsilon=10^{-7}$. При дополнительном обучении веса предварительно обученных CNN оставались зафиксированными, т.е. не изменялись, в процессе дополнительного обучения настраивались только веса двух добавленных полносвязных слоев.

Исходные данные

В настоящей работе использовались 2 общедоступные базы данных рентгеновских снимков грудной клетки:

1. Chest X-Ray Images (Pneumonia) [27].
2. COVID-19 image data collection [28].

Набор данных [27] 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.



а) Chest X-Ray Images

норма

б) COVID-19 image data collection

COVID-19

Рисунок 1 – Наборы данных: а) Chest X-Ray Images; б) COVID-19 image data collection

Набор [28] 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.

Из первого набора был выбран 191 рентгеновский снимок грудной клетки здоровых людей в передней прямой проекции (рис. 1 а), а из второго набора 191 снимок грудной клетки пациентов, больных COVID-19 (рис. 1б) в передней и задней прямой проекции с дополнением данных путем случайного поворота на величину до 15° и случайного отражения в горизонтальной плоскости. 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 сравнения с другими работами использовался отдельный набор данных, включающих 403 рентгеновских снимка грудной клетки с COVID-19 [27] и 721 рентгеновский снимок грудной клетки здоровых людей [28] без дополнения. Этот набор данных необходим для сравнения с исследованиями, опубликованными в работах [8, 12].

Методы оценки обученных нейронных сетей

Как и в работе [12] использовались 6 характеристик для сравнения результатов дополнительного обучения глубоких нейронных сетей на основе различных вариантов CNN – верность, чувствительность, специфичность, точность, оценка F_1 и площадь под ROC-кривой (receiver operating characteristic, рабочая характеристика приемника), т.н. AUC (area under ROC curve).

Чувствительность S_e определяется как процент пациентов с COVID-19, у которых инфекция правильно диагностирована, и выражается как:

$$S_e = T_p / P \times 100\% = T_p / (T_p + F_n) \times 100\%, \quad (1)$$

где T_p – количество пациентов с COVID-19, правильно идентифицированных как инфицированные; F_n – количество пациентов с COVID-19, ошибочно идентифицированных как не инфицированные и P – общее количество больных COVID-19.

Специфичность S_p определяется как процент людей, не инфицированных COVID-19, правильно идентифицированных как не инфицированные:

$$S_p = T_n / N \times 100\% = T_n / (T_n + F_p) \times 100\%, \quad (2)$$

где T_n – количество людей, не инфицированных COVID-19, правильно идентифицированных как не инфицированные; F_p – количество людей, не инфицированных COVID-19, ошибочно идентифицированных как инфицированные и N – общее количество людей, не инфицированных COVID-19.

Точность A_c классификации определяется как

$$A_c = (T_p + T_n) / (P + N) \times 100\%. \quad (3)$$

Верность P_r классификации определяется как

$$P_r = T_p / (T_p + F_p) \times 100\%. \quad (4)$$

Оценка F_1 определяется как среднее гармоническое между точностью и чувствительностью:

$$F_1 = 2T_p / (2T_p + F_p + F_n). \quad (5)$$

ROC представляет собой график, отображающий соотношение между T_p и F_p при варьировании порога решающего правила, а AUC представляет собой меру производительности классификатора. Чем выше AUC, тем лучше модель диагностирует COVID-19, отличая его от случаев, не связанных с ним. Для идеального классификатора $AUC=1$, а $AUC=0.5$ показывает, что классификатор работает случайным образом.

Результаты

Результаты представлены в табл. 2 в виде средних значений и доверительного интервала всех вышеперечисленных характеристик (1-5) для трёх случайных разбиений

Таблица 2. Результаты численного моделирования

№ п/п	CNN	Точность (%)	Чувствительность (%)	Специфичность (%)	Верность (%)	Оценка F ₁	AUC
10 эпох обучения							
<i>80% обучающих и 20% проверочных данных</i>							
1.	DenseNet121	97.4026±8.5356	100.0000±0.0000	94.7368±17.2958	95.3788±14.8338	0.9757±0.0789	0.9737±0.0865
2.	DenseNet169	100.0000±0.0000	100.0000±0.0000	100.0000±0.0000	100.0000±0.0000	1.0000±0.0000	1.0000±0.0000
3.	DenseNet201	98.2684±4.9280	99.1453±3.6775	97.3684±6.5372	97.5000±6.2103	0.9831±0.0480	0.9826±0.0495
4.	EfficientNetB0	50.2165±1.8626	66.6667±143.4218	33.3333±143.4218	-	0.4483±0.9644	0.5000±0.0000
5.	EfficientNetB1	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
6.	EfficientNetB2	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
7.	EfficientNetB3	50.2165±1.8626	66.6667±143.4218	33.3333±143.4218	-	0.4483±0.9644	0.5000±0.0000
8.	EfficientNetB4	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
9.	EfficientNetB5	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
10.	EfficientNetB6	50.6494±0.0000	100.0000±0.0000	0.0000±0.0000	50.6494±0.0000	0.6724±0.0000	0.5000±0.0000
11.	EfficientNetB7	50.2165±1.8626	66.6667±143.4218	33.3333±143.4218	-	0.4483±0.9644	0.5000±0.0000
12.	InceptionResNetV2	96.9697±1.8626	96.5812±3.6775	97.3684±6.5372	97.4786±6.2110	0.9700±0.0172	0.9697±0.0191
13.	InceptionV3	98.2684±1.8626	99.1453±3.6775	97.3684±6.5372	97.5407±6.0595	0.9831±0.0175	0.9826±0.0191
14.	MobileNet	98.7013±0.0000	100.0000±0.0000	97.3684±0.0000	97.5000±0.0000	0.9873±0.0000	0.9868±0.0000
15.	MobileNetV2	99.5671±1.8626	100.0000±0.0000	99.1228±3.7743	99.1667±3.5855	0.9958±0.0182	0.9956±0.0189
16.	MobileNetV3Large	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
17.	MobileNetV3Small	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
18.	NASNetLarge	99.1342±3.7252	100.0000±0.0000	98.2456±7.5485	98.3740±6.9962	0.9917±0.0359	0.9912±0.0377
19.	NASNetMobile	98.7013±3.2262	99.1453±3.6775	98.2456±7.5485	98.3740±6.9962	0.9873±0.0311	0.9870±0.0327
20.	ResNet101	91.3420±10.3706	95.7265±13.2593	86.8421±13.0744	88.2672±10.5787	0.9179±0.0996	0.9128±0.1037
21.	ResNet101V2	98.7013±0.0000	97.4359±0.0000	100.0000±0.0000	100.0000±0.0000	0.9870±0.0000	0.9872±0.0000
22.	ResNet152	80.9524±9.3131	82.9060±32.6862	78.9474±51.8875	82.8451±30.9197	0.8156±0.0241	0.8093±0.0985
23.	ResNet152V2	99.1342±1.8626	98.2906±3.6775	100.0000±0.0000	100.0000±0.0000	0.9913±0.0186	0.9915±0.0184
24.	ResNet50	90.9091±17.0712	91.4530±25.7424	90.3509±9.9857	90.5291±11.0412	0.9090±0.1795	0.9090±0.1696
25.	ResNet50V2	97.8355±1.8626	98.2906±3.6775	97.3684±6.5372	97.5193±6.0615	0.9788±0.0177	0.9783±0.0191
26.	VGG16	95.6710±4.9280	96.5812±9.7297	94.7368±0.0000	94.9529±0.4889	0.9574±0.0506	0.9566±0.0486

27.	VGG19	91.7749±9.8561	97.4359±6.3696	85.9649±13.6083	87.7706±11.3011	0.9234±0.0902	0.9170±0.0990
28.	Xception	99.5671±1.8626	99.1453±3.6775	100.0000±0.0000	100.0000±0.0000	0.9957±0.0186	0.9957±0.0184
10 эпох обучения							
<i>50% обучающих и 50% проверочных данных</i>							
1.	DenseNet121	97.2077±3.0036	97.5694±1.4940	96.8421±6.9183	96.9509±6.4735	0.9724±0.0285	0.9721±0.0302
2.	DenseNet169	98.2548±0.7509	97.5694±1.4940	98.9474±0.0000	98.9436±0.0161	0.9825±0.0077	0.9826±0.0075
3.	DenseNet201	97.7312±1.9867	96.8750±2.5876	98.5965±3.9943	98.6075±3.9497	0.9773±0.0196	0.9774±0.0199
4.	EfficientNetB0	50.0873±0.7509	66.6667±143.4218	33.3333±143.4218	-	0.4460±0.9595	0.5000±0.0000
5.	EfficientNetB1	49.9127±0.7509	33.3333±143.4218	66.6667±143.4218	-	0.2230±0.9595	0.5000±0.0000
6.	EfficientNetB2	50.0873±0.7509	66.6667±143.4218	33.3333±143.4218	-	0.4460±0.9595	0.5000±0.0000
7.	EfficientNetB3	50.2618±0.0000	100.0000±0.0000	0.0000±0.0000	50.2618±0.0000	0.6690±0.0000	0.5000±0.0000
8.	EfficientNetB4	50.0873±0.7509	66.6667±143.4218	33.3333±143.4218	-	0.4460±0.9595	0.5000±0.0000
9.	EfficientNetB5	50.0873±0.7509	66.6667±143.4218	33.3333±143.4218	-	0.4460±0.9595	0.5000±0.0000
10.	EfficientNetB6	49.9127±0.7509	33.3333±143.4218	66.6667±143.4218	-	0.2230±0.9595	0.5000±0.0000
11.	EfficientNetB7	49.9127±0.7509	33.3333±143.4218	66.6667±143.4218	-	0.2230±0.9595	0.5000±0.0000
12.	InceptionResNetV2	96.5096±1.9867	95.8333±2.5876	97.1930±6.0388	97.2365±5.9453	0.9651±0.0188	0.9651±0.0201
13.	InceptionV3	97.3822±3.4411	97.2222±5.3866	97.5439±8.4057	97.6575±7.8575	0.9740±0.0336	0.9738±0.0346
14.	MobileNet	98.4293±2.6012	96.8750±5.1753	100.0000±0.0000	100.0000±0.0000	0.9841±0.0267	0.9844±0.0259
15.	MobileNetV2	98.6038±1.5018	98.2639±2.9880	98.9474±0.0000	98.9509±0.0318	0.9860±0.0153	0.9861±0.0149
16.	MobileNetV3Large	49.7382±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
17.	MobileNetV3Small	49.9127±0.7509	33.3333±143.4218	66.6667±143.4218	-	0.2230±0.9595	0.5000±0.0000
18.	NASNetLarge	97.3822±1.3006	97.2222±1.4940	97.5439±1.5097	97.5621±1.4785	0.9739±0.0129	0.9738±0.0130
19.	NASNetMobile	97.0332±1.9867	96.8750±4.4819	97.1930±5.4433	97.2597±5.1218	0.9705±0.0194	0.9703±0.0199
20.	ResNet101	83.7696±8.1222	77.7778±47.8073	89.8246±32.6947	90.8597±23.9777	0.8215±0.1462	0.8380±0.0792
21.	ResNet101V2	96.1606±5.8647	96.5278±8.3181	95.7895±15.9057	96.1900±14.1889	0.9623±0.0543	0.9616±0.0591
22.	ResNet152	64.3979±24.3667	80.5556±83.6627	48.0702±108.8348	67.7593±44.1379	0.6768±0.2740	0.6431±0.2462
23.	ResNet152V2	97.3822±0.0000	96.1806±2.9880	98.5965±3.0194	98.5965±3.0194	0.9736±0.0008	0.9739±0.0002
24.	ResNet50	75.0436±31.2233	74.3056±108.3210	75.7895±54.0339	81.3036±33.1748	0.6931±0.6700	0.7505±0.3085
25.	ResNet50V2	97.0332±0.7509	96.8750±6.8463	97.1930±6.5806	97.3024±6.2683	0.9704±0.0082	0.9703±0.0074
26.	VGG16	94.2408±2.6012	92.7083±8.9639	95.7895±10.4595	95.8945±9.8579	0.9418±0.0258	0.9425±0.0262
27.	VGG19	92.3211±3.9734	95.4861±6.5121	89.1228±1.5097	89.8602±1.8654	0.9258±0.0402	0.9230±0.0396

28.	Xception	98.2548±1.5018	98.2639±5.3866	98.2456±3.9943	98.2993±3.8720	0.9826±0.0153	0.9825±0.0149
	30 эпох обучения						
	<i>80% обучающих и 20% проверочных данных</i>						
1.	DenseNet121	99.1342±1.8626	100.0000±0.0000	98.2456±3.7743	98.3333±3.5855	0.9916±0.0182	0.9912±0.0189
2.	DenseNet169	98.7013±3.2262	99.1453±3.6775	98.2456±7.5485	98.3740±6.9962	0.9873±0.0311	0.9870±0.0327
3.	DenseNet201	98.7013±3.2262	100.0000±0.0000	97.3684±6.5372	97.5407±6.0595	0.9874±0.0311	0.9868±0.0327
4.	EfficientNetB0	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
5.	EfficientNetB1	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
6.	EfficientNetB2	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
7.	EfficientNetB3	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
8.	EfficientNetB4	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
9.	EfficientNetB5	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
10.	EfficientNetB6	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
11.	EfficientNetB7	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
12.	InceptionResNetV2	96.9697±1.8626	96.5812±3.6775	97.3684±6.5372	97.4786±6.2110	0.9700±0.0172	0.9697±0.0191
13.	InceptionV3	99.1342±3.7252	100.0000±0.0000	98.2456±7.5485	98.3740±6.9962	0.9917±0.0359	0.9912±0.0377
14.	MobileNet	100.0000±0.0000	100.0000±0.0000	100.0000±0.0000	100.0000±0.0000	1.0000±0.0000	1.0000±0.0000
15.	MobileNetV2	99.5671±1.8626	100.0000±0.0000	99.1228±3.7743	99.1667±3.5855	0.9958±0.0182	0.9956±0.0189
16.	MobileNetV3Large	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
17.	MobileNetV3Small	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
18.	NASNetLarge	98.7013±5.5879	99.1453±3.6775	98.2456±7.5485	98.3333±7.1711	0.9873±0.0545	0.9870±0.0561
19.	NASNetMobile	98.7013±3.2262	99.1453±3.6775	98.2456±7.5485	98.3740±6.9962	0.9873±0.0311	0.9870±0.0327
20.	ResNet101	88.3117±12.9046	85.4701±13.2593	91.2281±13.6083	90.9357±14.1546	0.8810±0.1326	0.8835±0.1291
21.	ResNet101V2	98.7013±5.5879	99.1453±3.6775	98.2456±7.5485	98.3333±7.1711	0.9873±0.0545	0.9870±0.0561
22.	ResNet152	89.6104±8.5356	94.0171±13.2593	85.0877±15.0970	86.8079±11.9680	0.9016±0.0808	0.8955±0.0855
23.	ResNet152V2	99.5671±1.8626	99.1453±3.6775	100.0000±0.0000	100.0000±0.0000	0.9957±0.0186	0.9957±0.0184
24.	ResNet50	92.6407±13.0383	92.3077±27.7644	92.9825±7.5485	93.1792±5.9976	0.9248±0.1444	0.9265±0.1286
25.	ResNet50V2	98.2684±1.8626	99.1453±3.6775	97.3684±0.0000	97.4786±0.0919	0.9830±0.0186	0.9826±0.0184
26.	VGG16	99.1342±3.7252	99.1453±3.6775	99.1228±3.7743	99.1453±3.6775	0.9915±0.0368	0.9913±0.0373
27.	VGG19	95.2381±3.7252	99.1453±3.6775	91.2281±3.7743	92.0635±3.4148	0.9547±0.0354	0.9519±0.0373
28.	Xception	99.1342±3.7252	100.0000±0.0000	98.2456±7.5485	98.3740±6.9962	0.9917±0.0359	0.9912±0.0377

30 эпох обучения							
<i>80% обучающих и 20% проверочных данных</i>							
1.	DenseNet121	99.1342±1.8626	100.0000±0.0000	98.2456±3.7743	98.3333±3.5855	0.9916±0.0182	0.9912±0.0189
2.	DenseNet169	98.7013±3.2262	99.1453±3.6775	98.2456±7.5485	98.3740±6.9962	0.9873±0.0311	0.9870±0.0327
3.	DenseNet201	98.7013±3.2262	100.0000±0.0000	97.3684±6.5372	97.5407±6.0595	0.9874±0.0311	0.9868±0.0327
4.	EfficientNetB0	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
5.	EfficientNetB1	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
6.	EfficientNetB2	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
7.	EfficientNetB3	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
8.	EfficientNetB4	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
9.	EfficientNetB5	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
10.	EfficientNetB6	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
11.	EfficientNetB7	49.7835±1.8626	33.3333±143.4218	66.6667±143.4218	-	0.2241±0.9644	0.5000±0.0000
12.	InceptionResNetV2	96.9697±1.8626	96.5812±3.6775	97.3684±6.5372	97.4786±6.2110	0.9700±0.0172	0.9697±0.0191
13.	InceptionV3	99.1342±3.7252	100.0000±0.0000	98.2456±7.5485	98.3740±6.9962	0.9917±0.0359	0.9912±0.0377
14.	MobileNet	100.0000±0.0000	100.0000±0.0000	100.0000±0.0000	100.0000±0.0000	1.0000±0.0000	1.0000±0.0000
15.	MobileNetV2	99.5671±1.8626	100.0000±0.0000	99.1228±3.7743	99.1667±3.5855	0.9958±0.0182	0.9956±0.0189
16.	MobileNetV3Large	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
17.	MobileNetV3Small	49.3506±0.0000	0.0000±0.0000	100.0000±0.0000	-	0.0000±0.0000	0.5000±0.0000
18.	NASNetLarge	98.7013±5.5879	99.1453±3.6775	98.2456±7.5485	98.3333±7.1711	0.9873±0.0545	0.9870±0.0561
19.	NASNetMobile	98.7013±3.2262	99.1453±3.6775	98.2456±7.5485	98.3740±6.9962	0.9873±0.0311	0.9870±0.0327
20.	ResNet101	88.3117±12.9046	85.4701±13.2593	91.2281±13.6083	90.9357±14.1546	0.8810±0.1326	0.8835±0.1291
21.	ResNet101V2	98.7013±5.5879	99.1453±3.6775	98.2456±7.5485	98.3333±7.1711	0.9873±0.0545	0.9870±0.0561
22.	ResNet152	89.6104±8.5356	94.0171±13.2593	85.0877±15.0970	86.8079±11.9680	0.9016±0.0808	0.8955±0.0855
23.	ResNet152V2	99.5671±1.8626	99.1453±3.6775	100.0000±0.0000	100.0000±0.0000	0.9957±0.0186	0.9957±0.0184
24.	ResNet50	92.6407±13.0383	92.3077±27.7644	92.9825±7.5485	93.1792±5.9976	0.9248±0.1444	0.9265±0.1286
25.	ResNet50V2	98.2684±1.8626	99.1453±3.6775	97.3684±0.0000	97.4786±0.0919	0.9830±0.0186	0.9826±0.0184
26.	VGG16	99.1342±3.7252	99.1453±3.6775	99.1228±3.7743	99.1453±3.6775	0.9915±0.0368	0.9913±0.0373
27.	VGG19	95.2381±3.7252	99.1453±3.6775	91.2281±3.7743	92.0635±3.4148	0.9547±0.0354	0.9519±0.0373
28.	Xception	99.1342±3.7252	100.0000±0.0000	98.2456±7.5485	98.3740±6.9962	0.9917±0.0359	0.9912±0.0377

данных на обучающие и проверочные. Пятнадцать дополнительно обученных моделей достигли достаточно высокой точности, превышающей 92%, чувствительности, специфичности, верности, показателя F_1 и AUC при двух различных пропорциях разбиения данных на обучающие и проверочные наборы, в табл. 2 их названия отмечены жирным шрифтом. В первом случае обучающие данные составляли 80%, а проверочные 20 %, во втором случае – по 50%.

Для этих нейронных сетей на рис. 2 показано изменение точности классификации на проверочном наборе данных в процессе обучения на протяжении 200 эпох. Для восьми из

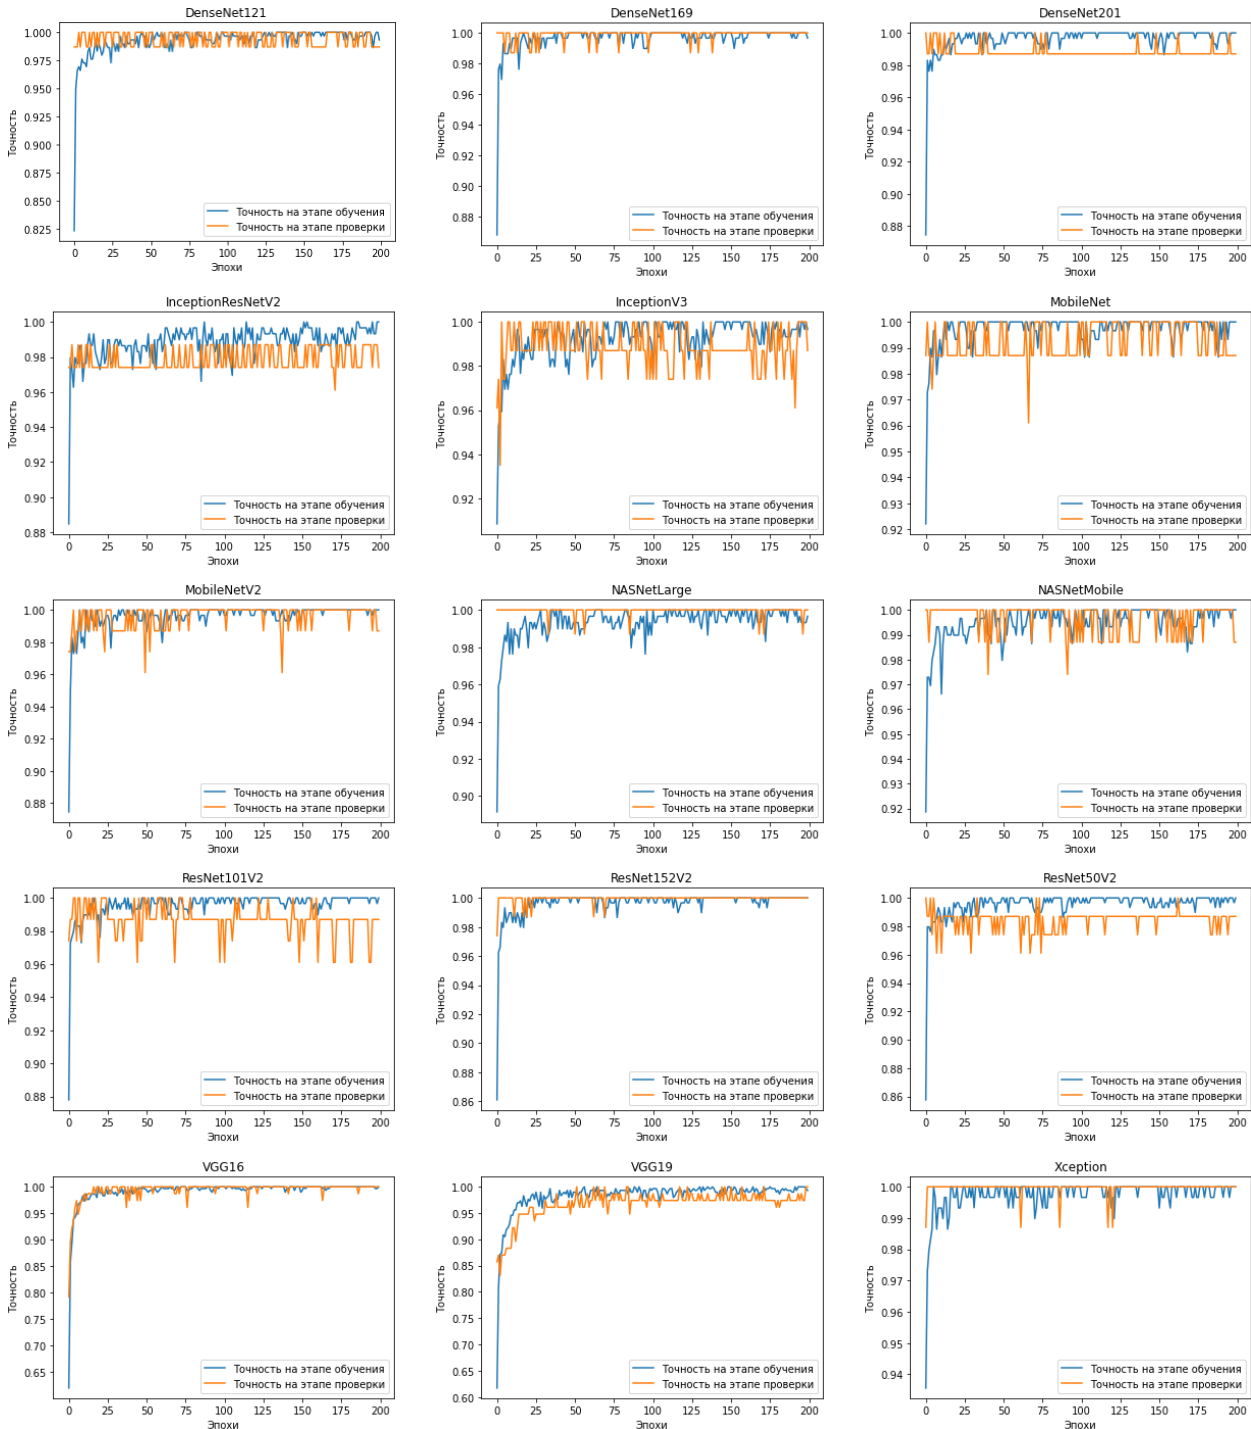
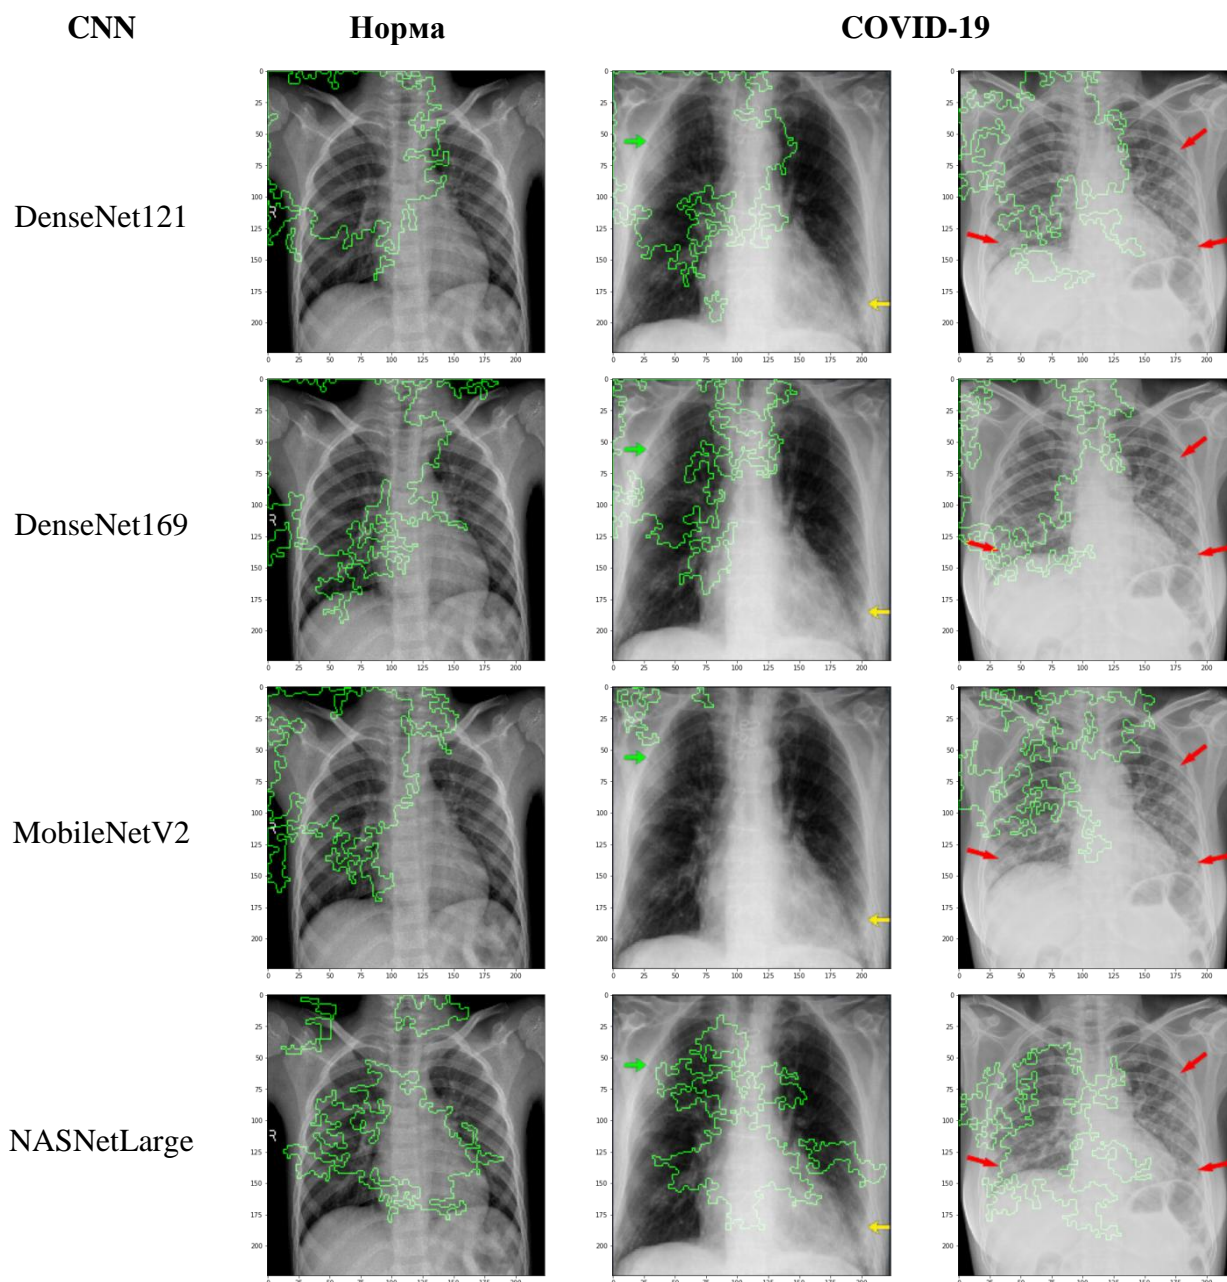


Рисунок 2 – Точность классификации на этапе обучения и проверки нейронных сетей на основе различных предварительно обученных CNN

этих моделей, показавших наиболее стабильное обучение, а именно построенных на основе предварительно обученных CNN DenseNet121, DenseNet169, MobileNetV2, NASNetLarge, ResNet152V2, VGG16, VGG19, Xception и дополнительно обученных на протяжении 50 эпох, созданы интерпретации взаимосвязи входных изображений с результатами классификации моделей по методу интегрированных градиентов [29] с количеством шагов, равных 100. Для построения показанных на рис. 3 визуализаций интегрированного градиента использовались пиксели с уровнем значений от 30% до 95% с применением трех изображений из наборов [17, 18], два из которых принадлежат больным COVID-19, а одно – здоровому человеку. Результаты, полученные с помощью дополнительного обучения нейронных сетей на основе предварительно обученных CNN DenseNet169, NASNetLarge, ResNet152V2, наиболее согласуются с мнением экспертов, в смысле соответствия участков изображения, использованных ими для классификации и участков легких, пораженных COVID-19.






Рисунок 3 – Интерпретация результатов классификации с помощью сетей на основе различных CNN, полученных на основе метода интегрированных градиентов

Обсуждение

Результаты, полученные в результате дополнительного обучения предварительно обученных сетей DenseNet169, NASNetLarge, ResNet152V2, демонстрируют высокую эффективность этих моделей для диагностики COVID-19. Однако из-за постоянных обновлений базы данных рентгеновских снимков и общедоступности других коллекций данных невозможно провести точное сравнение результатов, представленных здесь и в работах [6-12].

Сравнение с некоторыми работами [8, 12] при использовании идентичного набора данных, приведенное в таблице 3, убедительно свидетельствует о том, что *обученные до достижения максимальной точности* нейронные сети на основе предварительно обученных CNN DenseNet169 и ResNet152V2 достигли такого же, или даже лучшего результата, чем несколько других моделей с точки зрения точности классификации и разных соотношений объема данных для обучения и проверки.

Таблица 3. Сравнение результатов дополнительного обучения нейронных сетей на основе выбранных предварительно обученных CNN с другими моделями

Модели	Обучающие данные (%)	Тестовые данные (%)	Точность (%)
CovidGAN [8]	80	20	95
AlexNet [12]	80	20	99
GoogLeNet [12]	80	20	100
SqueezeNet [12]	80	20	100
DenseNet169	80	20	100
NASNetLarge	80	20	99
ResNet152V2	80	20	100
AlexNet [12]	50	50	99
GoogLeNet [12]	50	50	99
SqueezeNet [12]	50	50	98
DenseNet169	50	50	100
NASNetLarge	50	50	99
ResNet152V2	50	50	100

Заключение

Таким образом, в работе были проанализированы результаты дополнительного обучения нейронных сетей на основе 28 популярных предварительно обученных CNN, доступных с помощью фреймворка Keras, для классификации рентгеновских снимков грудной клетки пациентов, больных COVID19 и здоровых людей, с использованием общедоступных наборов данных. Результаты классификации, полученные с помощью различных наборов данных для обучения и проверки, позволили продемонстрировать высокую эффективность 2 из 28 исследованных предварительно обученных CNN. Эти результаты свидетельствуют, что правильный выбор предварительно обученной CNN важен, поскольку он помогает избежать усилий по разработке более сложных моделей, в то время как уже существующие предварительно обученные CNN позволяют добиться такого же или даже лучшего результата.

Из-за ограниченного объема доступных данных в этом исследовании не рассматривалась более подробная классификация на вирусную, бактериальную пневмонию и туберкулез. Другая проблема заключается в том, что для каждого пациента 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 [30]. Тем не менее результаты, представленные в этом исследовании, указывают на эффективность предварительно обученных CNN DenseNet169 и ResNet152V2 для решения подобного рода задач, что может помочь при создании более сложных и совершенных СИИ.

Литература

1. Cohen J., Kupferschmidt K. Strategies shift as coronavirus pandemic looms. Science. –2020. – 367с.
2. Лучевая диагностика коронавирусной болезни (COVID-19): организация, методология, интерпретация результатов: методические рекомендации / Сост. С. П. Морозов, Д. Н.

- Проценко, С.В. Сметанина [и др.] // Серия «Лучшие практики лучевой и инструментальной диагностики». - Вып. 65. - М.: ГБУЗ «НПКЦ ДиТ ДЗМ», 2020.
3. Burns J, Movsisyan A, Stratil JM, et al. Travel-related control measures to contain the COVID-19 pandemic: a rapid review. *Cochrane Database of Systematic Reviews* 2020, Issue 9. Art. No.: CD013717. DOI: 10.1002/14651858.CD013717.
 4. Wong HYF, Lam HYS, Fong AH-T, Leung ST, Chin TWY, et al. Frequency and distribution of chest radiographic findings in COVID-19 positive patients. *Radiology*. – 2020.
 5. Zech JR, Badgeley MA, Liu M, Costa AB, Titano JJ, Oermann EK. Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: a cross-sectional study. *PLoS Med*. 2018;15:e1002683.
 6. Ucar F, Korkmaz D. COVIDiagnosis-net: deep bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Med Hypotheses*. 2020;140:109761.
 7. Khan AI, Shah JL, Bhat MM. CoroNet: a deep neural network for detection and diagnosis of COVID-19 from chest x-ray images. *Comput Methods Programs Biomed*. 2020;196:105581.
 8. Waheed A, Goyal M, Gupta D, Khanna A, Al-Turjman F, Pinheiro PR. CovidGAN: data augmentation using auxiliary classifier GAN for improved Covid-19 detection. *IEEE Access*. 2020;8:91916–23.
 9. Ozturk T, Talo M, Yildirim EA, Baloglu UB, Yildirim O, Acharya UR. Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Comput Biol Med*. 2020;121:103792.
 10. Redmon J, Farhadi A. Yolo9000: better, faster, stronger. *arXiv* 2016; 1612.08242
 11. Apostolopoulos ID, Mpesiana TA. Covid. 19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Phys Eng Sci Med*. 2020;43:635–40.
 12. Pham, T.D. Classification of COVID-19 chest X-rays with deep learning: new models or fine tuning?. *Health Inf Sci Syst* 9, 2 (2021). <https://doi.org/10.1007/s13755-020-00135-3>
 13. <https://arxiv.org/abs/1608.06993> (дата обращения: 23.03.2021)
 14. <https://arxiv.org/abs/1905.11946> (дата обращения: 23.03.2021)
 15. <https://arxiv.org/abs/1602.07261> (дата обращения: 23.03.2021)
 16. <https://arxiv.org/abs/1512.00567> (дата обращения: 23.03.2021)
 17. <https://arxiv.org/abs/1704.04861> (дата обращения: 23.03.2021)
 18. <https://arxiv.org/abs/1801.04381> (дата обращения: 23.03.2021)
 19. <https://arxiv.org/abs/1905.02244> (дата обращения: 23.03.2021)
 20. <https://arxiv.org/abs/1707.07012> (дата обращения: 23.03.2021)
 21. <https://arxiv.org/abs/1512.03385> (дата обращения: 23.03.2021)
 22. <https://arxiv.org/abs/1603.05027> (дата обращения: 23.03.2021)
 23. <https://arxiv.org/abs/1409.1556> (дата обращения: 23.03.2021)
 24. <https://arxiv.org/abs/1610.02357> (дата обращения: 23.03.2021)
 25. <https://keras.io> (дата обращения: 30.03.2021)
 26. <https://arxiv.org/abs/1904.09237> (дата обращения: 30.03.2021)
 27. Daniel S. Kermany et al, 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>.
 28. 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
 29. <https://arxiv.org/abs/1703.01365> (дата обращения 29.03.2021)
 30. Weinstock MB, et al. Chest X-ray findings in 636 ambulatory patients with COVID-19 presenting to an urgent care center: a normal chest X-ray is no guarantee. *J Urgent Care Med*. 2020;14:13–8.25