



ISSN 1607-0763 (Print); ISSN 2408-9516 (Online)

<https://doi.org/10.24835/1607-0763-1243>

Использование трансферного обучения для автоматизированного поиска дефектов на рентгенограммах органов грудной клетки

© Борисов А.А.^{1,2}, Семенов С.С.^{2*}, Арзамасов К.М.²

¹ ФГАОУ ВО «Российский национальный исследовательский медицинский университет им. Н.И. Пирогова» Минздрава России; 117997 Москва, ул. Островитянова, дом 1, Российская Федерация

² ГБУЗ города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий ДЗ города Москвы»; 127051 Москва, ул. Петровка, д. 24, стр. 1, Российская Федерация

Цель исследования: разработать и протестировать алгоритмы определения проекции и поиска пространственных технических дефектов на рентгенограммах органов грудной клетки (ОГК) при помощи трансферного обучения, используя различные нейросетевые архитектуры.

Материал и методы. Определялись такие несоответствия методики сканирования на рентгенограммах как некорректный выбор границ исследования, нарушение укладки и позиционирования пациентов. В качестве основы для создания алгоритмов было выбрано трансферное обучение нейросетевых архитектур VGG19 и ResNet152V2. Для обучения и тестирования алгоритмов были использованы рентгенограммы из баз данных с открытым доступом (общий объем более 230 тыс. исследований). Для валидации полученных алгоритмов был подготовлен тестовый набор данных из 150 анонимизированных рентгенограмм ОГК, полученных из Единого радиологического информационного сервиса города Москвы (ЕРИС) и оцененных врачами-экспертами и лаборантами-экспертами.

Результаты. Все полученные алгоритмы имеют высокие показатели качества классификации. Максимальная точность на тестовом наборе данных была получена для модели, определяющей проекцию, AUC составил 1,0, минимальная точность: AUC 0,968 была получена для модели, определяющей ротацию грудной клетки на боковой проекции. На валидационном наборе данных максимальная точность была получена для модели, определяющей проекцию, AUC составил 0,996, минимальная точность: AUC 0,898 была получена для модели, определяющей ротацию грудной клетки на боковой проекции.

Заключение. По значениям метрик диагностической точности для каждой из задач разработанные алгоритмы превысили пороговое значение в 0,81 и могут быть рекомендованы к практическому применению.

Ключевые слова: рентгенограммы грудной клетки, контроль качества, машинное обучение, искусственные нейронные сети, глубокие сверточные нейронные сети, трансферное обучение

Источник финансирования: авторы заявляют об отсутствии внешнего финансирования при проведении поисково-аналитической работы и подготовке статьи.

Конфликт интересов: авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Борисов А.А., Семенов С.С., Арзамасов К.М. Использование трансферного обучения для автоматизированного поиска дефектов на рентгенограммах органов грудной клетки. *Медицинская визуализация*. 2023; 27 (1): 158–169. <https://doi.org/10.24835/1607-0763-1243>


Поступила в редакцию: 10.10.2022. Принята к печати: 8.11.2022. Опубликовано online: 08.02.2023.

Transfer Learning for automated search for defects on chest X-rays

© Alexander A. Borisov^{1,2}, Serafim S. Semenov^{2*}, Kirill M. Arzamasov²

¹ Pirogov Russian National Research Medical University (Pirogov Medical University); 1, Ostrovityanova str., Moscow 117997, Russian Federation

² Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department; 24-1, Petrovka str., Moscow 127051, Russian Federation



Purpose. To develop and test algorithms for determining the projection and searching for common technical defects on chest X-rays using transfer learning with various neural network architectures.

Materials and methods. Algorithms have been created to search for technical remarks such as incorrect choice of study boundaries and errors of patient positioning. Transfer learning of neural network architectures VGG19 and ResNet152V2 was chosen as the basis for creating algorithms. To train and test the algorithms, we used radiographs from open databases (over 230,000 studies in total). To validate the obtained algorithms, a test dataset was prepared from 150 anonymized chest X-rays unloaded from the Unified Radiological Information Service of the Moscow city (URIS) and evaluated by expert doctors and technicians.

Results. All obtained algorithms have high classification quality indicators. The maximum accuracy on the test dataset was obtained for the model that determines the projection, AUC was 1.0, the minimum accuracy: AUC 0.968 was obtained for the model that determines the rotation of the chest on the lateral X-ray. On the validation dataset maximum accuracy was obtained for the model that determines the projection, AUC was 0.996, the minimum accuracy: AUC 0.898 was obtained for the model that determines the rotation of the chest on the lateral X-ray.

Conclusions. All of diagnostic accuracy metrics for each of the models exceeded the threshold value of 0.81 and can be recommended for practical use.

Keywords: chest X-ray, quality assurance, machine learning, artificial neural network, Deep convolutional neural networks, transfer learning

Conflict of interest. The authors declare no conflict of interest. The study had no sponsorship.

For citation: Borisov A.A., Semenov S.S., Arzamasov K.M. Transfer Learning for automated search for defects on chest X-rays. *Medical Visualization*. 2023; 27 (1): 158–169. <https://doi.org/10.24835/1607-0763-1243>

Received: 10.10.2022.

Accepted for publication: 8.11.2022.

Published online: 08.02.2023.

Введение

Одним из наиболее распространенных рентгенографических исследований является рентгенография органов грудной клетки (ОГК). Рентгенография ОГК является скрининговым методом, позволяющим выявить патологические изменения анатомических структур, расположенных в грудной полости. Качество выполненного рентгенологического исследования напрямую влияет на правильность интерпретации, точность постановки медицинского диагноза и опосредованно на выбор тактики ведения пациента.

Также немаловажно обеспечение технического качества и правильной маркировки рентгенограмм для разработки алгоритмов машинного обучения, которые в дальнейшем могут использоваться для контроля качества исследований, полученных в разных медицинских организациях [1].

При выполнении рентгенографии могут возникать ошибки, по большей части обусловленные человеческим фактором, которые затрудняют интерпретацию изображения и дальнейшую, в том числе автоматическую, его обработку. Исследование N. Shet и соавт. показало, что процент брака для рентгенограмм ОГК, выполненных рентгенолаборантами одного учреждения, может варьироваться от менее 1% до более чем 8% [2].

Развитие методов медицинской визуализации, сильно повысившее диагностические возможности оказываемой медицинской помощи, привело к непропорциональному росту объема данных рентгенологических изображений по сравнению с количеством доступных обученных врачей. Это способствовало резкому увеличению рабочей на-

грузки рентгенологов [3]. В условиях высокой нагрузки на врача контроль качества изображений отходит на второй план. За редкими исключениями, изображения подлежат только быстрому просмотру, чтобы убедиться, что интересующие анатомические области включены в поле зрения перед их расшифровкой [4].

Ручная оценка качества утомительна и способна привести к неверной трактовке рентгенологического изображения [5]. Также ручная оценка требует от врача большего времени, что не допустимо в существующих реалиях. Учитывая, что рентгеновские изображения существуют в цифровой форме, логично предположить, что автоматизация может решить проблему задержки при контроле качества, в противном случае для диагностики могут использоваться неоптимальные исследования [4].

Актуальность автоматизации обеспечения качества медицинских изображений обусловлена также тем, что на сегодняшний день в рутинную практику входит дистанционное описание рентгенологических исследований (телерадиология как частный случай телемедицинских технологий) [6–10]. В таких условиях рентгенолаборанты выполняют сканирование пациентов без возможной курации и консультации со стороны врачей-рентгенологов, что делает качество исследований полностью зависимым от квалификации среднего медицинского персонала, что подтверждается отечественными исследованиями [11].

Алгоритмы машинного обучения активно применяются исследователями для классификации рентгенологических изображений ОГК. А. Rajkomar и соавт. создали алгоритм классификации проек-



ции рентгенограмм грудной клетки на фронтальную или боковую, предложив решение проблемы недостаточного доступа к рентгенологическим изображениям. В своей работе они предположили, что повторное обучение ранее существовавших, более общих сетей с использованием изображений в градациях серого улучшает качество классификации на рентгенограммах. Задача классификации была успешно ими решена. Точность определения проекции составила 100% на данных из другой организации [12].

Т.К. Kim также использовали метод трансферного обучения в задаче автоматизированной классификации фронтальных рентгеновских снимков на виды AP (Antero-Posterior, переднезадние) или PA (Postero-Anterior, заднепередние). Их системы глубокого обучения достигли высоких показателей для взрослого и педиатрического населения, демонстрируя высокую диагностическую эффективность для различных демографических групп [1].

Цель исследования

Разработать и протестировать алгоритмы поиска ряда распространенных дефектов на рентгенограммах ОГК при помощи трансферного обучения, используя нейросетевые архитектуры VGG19 и ResNet152V2.

Материал и методы

Сбор и предобработка данных, создание обучающей и тестовой выборок

Для обучения алгоритмов автоматизированной оценки качества использовались наборы рентгенограмм ОГК в прямой и боковой проекциях, взятые из открытых источников. Использовались наборы данных: CheXpert от клиники Стэнфордского университета [13], содержащий по 112 158 рентгенограмм ОГК в прямой и боковой проекциях; Chest X-rays от Индианского университета США [14]; Dataset Chest X-Ray Images (Pneumonia) [15]; NIH ChestX-ray14 от Национального института здоровья США (NIH) [16], содержащий 112 120 фронтальных рентгенограмм ОГК с метками 14 заболеваний. Данные наборы данных содержат изображения рентгенограмм ОГК в форматах PNG, JPEG и JPG различного разрешения. Поиск изображений с технологическими дефектами производился вручную в данных наборах. Наборы для обучения и проверки были дополнены путем применения аугментации (искусственного увеличения количества обучающих изображений путем применения к ним случайных преобразований): вертикального отражения, поворота на 2 или 3°, изменения яркости пикселей, обрезки изображения.

Были созданы 4 модели: модель определения проекции на рентгенограммах ОГК, модели определения некорректного выбора границ исследования на прямой и боковой проекциях, модель определения ротации грудной клетки на боковой проекции рентгенограмм ОГК. Для каждой модели были подготовлены обучающий и тестовый наборы данных:

Для модели, определяющей проекцию на рентгенограммах ОГК, размер обучающей выборки составил 2005 рентгенограмм. Из них 778 (38,9%) рентгенограмм в прямой и 1227 (61,1%) в боковой проекциях. Размер тестовой выборки составил 231 рентгенограмму. Из них 116 (50%) в прямой и 115 (50%) в боковой проекциях.

Для модели определения некорректного выбора границ исследования на прямой проекции (рис. 1) размер обучающей выборки составил 13 580 рентгенограмм. Из них 6732 (49,6%) рентгенограммы с полной визуализацией границ легких и 6848 (50,4%) с обрезанными границами. Размер тестовой выборки составил 2332 рентгенограммы. Из них 1075 (46,1%) с полной визуализацией границ легких и 1257 (53,9%) с обрезанными границами.

Для модели, определяющей некорректный выбор границ исследования на боковой проекции, размер обучающей выборки составил 8152 рентгенограммы. Из них 4131 (50,7%) рентгенограмма с полной визуализацией границ легких и 4021 (49,3%) с обрезанными границами. Размер тестовой выборки составил 1445 рентгенограмм. Из них 738 (51,1%) с полной визуализацией границ легких и 707 (48,9%) с обрезанными границами.

Для модели, определяющей ротацию грудной клетки на боковой проекции рентгенограмм ОГК (см. рис. 1), размер обучающей выборки составил 15 453 рентгенограммы. Из них 7940 (51,4%) рентгенограмм без ротации грудной клетки и 7513 (48,6%) с ротацией. Размер тестовой выборки составил 2664 рентгенограммы. Из них 1357 (50,9%) без ротации грудной клетки и 1307 (49,1%) с ротацией.

В качестве независимого тестового набора использовался набор анонимизированных рентгенограмм ОГК в формате DICOM, полученный из Единого радиологического информационного сервиса города Москвы (ЕРИС) и оцененный экспертами на предмет наличия технологических дефектов изображений экспертами двух групп – врачами-экспертами и лаборантами-экспертами (в рамках реализации постановления ДЗ города Москвы о плановом анализе исследований в ЕРИС [17]). Размер набора составил 150 рентгенограмм ОГК. Из них 84 (56%) рентгенограммы в прямой






Рис. 1. **а** – исследование рентгенограмм ОГК с некорректным выбором границ исследования – неполный захват зоны интереса (отсутствуют части легочного поля и реберно-диафрагмальные углы на изображениях в прямой проекции); **б** – исследование рентгенограмм ОГК с нарушением укладки и позиционирования – чрезмерная ротация туловища на изображении в боковой проекции.

Fig. 1. **a** – chest X-ray with an incorrect choice of study boundaries – incomplete capture of the area of interest (parts of the lung field and costal-diaphragmatic angles are missing on the frontal X-ray); **b** – chest X-ray with errors of styling and positioning – excessive rotation of the chest on the lateral X-ray.

и 66 (44%) в боковой проекциях. На рентгенограммах присутствовали следующие дефекты: 9 рентгенограмм в боковой проекции имели обрезанные границы легких; 21 рентгенограмма в прямой проекции имела обрезанные границы легких; на 40 рентгенограммах в боковой проекции наблюдалась чрезмерная ротация пациента.

Изображения в формате DICOM претерпевали ряд преобразований для приведения их к формату, используемому моделями. Позитивные изображения, имеющие значение DICOM тега (0028, 0004) Photometric Interpretation – “MONOCHROME1”, преобразовывались в негативные путем инверсии значения пикселей. Все изображения проходили эквализацию гистограмм яркости изображения для коррекции слишком светлых и темных рентгенограмм. Изображения были преобразованы в 8-битный формат PNG и размер каждого изображения был изменен до 244 на 244 пикселя, неквадратные изображения были сжаты до этого размера.

Выбор модели

Так как обучение нейросетей требует большого количества данных, а некоторые дефекты рентгенограмм в открытых наборах данных встречаются редко, необходимо было выбрать подходы, использующие меньшее количество обучающих данных.

В качестве такого подхода было выбрано трансферное обучение. Для работы над поставленными задачами были выбраны две нейросетевые архитектуры VGG19 и ResNet152V2, предобученные на базе данных изображений ImageNet, содержащей около 15 млн аннотированных немедицинских изображений.

VGG19 – это глубокая CNN, используемая для классификации изображений. Она содержит 16 сверточных блоков, состоящих из сверточного и объединяющего слоев, 3 полносвязных слоя и выходной слой с функцией softmax. ResNet152V2 – это глубокая CNN, состоящая из 152 слоев архитектуры ResNetV2. По глубине ResNet152V2 превосходит VGG19 в 8 раз, но имеет меньшую насыщенность параметрами – 58 331 648 параметров на 152 слоя против 20 024 384 параметров на 19 слоев у VGG19. При решении различных задач обработки изображений эти архитектуры конкурируют друг с другом как самые эффективные [18].

Так как данные нейросетевые архитектуры не обучены работе с рентгенограммами, к ним добавлялись 3 дополнительных полносвязных слоя и выходной слой с функцией sigmoid, подходящей для задачи бинарной классификации. При этом веса внутри архитектур замораживались, что позволяет сохранить паттерны работы с изображе-



ниями, изученные на ImageNet, а настройка весов дополнительных слоев позволяет решить поставленную специфическую задачу.

Обе сети обучались на одинаковом наборе данных, затем оценивались их эффективность и качество классификации на тестовой выборке. После этого полученные модели использовали для работы с независимым валидационным набором данных.

Статистический анализ

Для каждого результата классификации строилась матрица ошибок и рассчитывались стандартные диагностические характеристики (precision, recall, f-мера). Качество классификации оценивалось с помощью логистической функции потерь (Logloss), показывающей, насколько сильно предсказания модели отличаются от ожидаемого ре-

зультата. Для каждой классификации строились ROC-кривые, рассчитывалась площадь под кривой (AUC) и определялось пороговое значение методом максимизации индекса Юдена с использованием открытого отечественного инструмента ROC-анализа [19].

Результаты

Определение проекции на рентгенограммах ОГК

Метрики классификаций для моделей ResNet152V2 и VGG 19 на тестовом и валидационном наборах данных представлены в таблице. ROC-кривые для тестового набора данных представлены на рис. 2.

Обе модели с высокой точностью произвели классификацию, но модель ResNet152V2 допустила одну классификационную ошибку.

Таблица. Результаты тестирования моделей ResNet152V2 и VGG19

Table. ResNet152V2 and VGG19 model testing results

	Тестовый набор данных Test dataset		Валидационный набор данных Validation dataset	
	ResNet152V2	VGG19	ResNet152V2	VGG19
Определение проекции/ Determining of x-ray projection				
AUC	1,0 [1,0; 1,0]	1,0 [1,0; 1,0]	0,992 [0,983; 1]	0,996 [0,99; 1]
Precision	0,991 [0,965; 991]	1,0 [0,976; 1,0]	0,955 [0,894; 0,984]	0,970 [0,914; 0,992]
Recall	1,0 [0,974; 1,0]	1,0 [0,976; 1,0]	0,955 [0,894; 0,984]	0,970 [0,914; 0,992]
F1-мера	0,995 [0,976; 1,0]	1,0 [0,984; 1,0]	0,955 [0,906; 0,981]	0,970 [0,924; 0,989]
Определение некорректного выбора границ исследования на прямой проекции Determining the incorrect choice of the study boundaries on the frontal chest X-ray				
AUC	0,989 [0,986; 0,992]	0,982 [0,979; 0,986]	0,866 [0,779; 0,954]	0,972 [0,93; 1]
Precision	0,960 [0,949; 0,969]	0,900 [0,888; 0,912]	0,625 [0,455; 0,743]	0,947 [0,785; 0,995]
Recall	0,924 [0,913; 0,933]	0,929 [0,916; 0,941]	0,750 [0,546; 0,892]	0,947 [0,785; 0,995]
F1-мера	0,942 [0,932; 0,951]	0,914 [0,902; 0,925]	0,682 [0,566; 0,779]	0,947 [0,880; 0,987]
Определение некорректного выбора границ исследования на боковой проекции Determining the incorrect choice of the study boundaries on the lateral chest X-ray				
AUC	0,992 [0,989; 0,995]	0,995 [0,992; 0,997]	0,621 [0,384; 0,848]	0,926 [0,858; 0,995]
Precision	0,951 [0,938; 0,961]	0,966 [0,954; 0,975]	0,206 [0,112; 0,254]	0,5 [0,317; 0,500]
Recall	0,955 [0,942; 0,965]	0,959 [0,947; 0,968]	0,778 [0,424; 0,960]	1,0 [0,634; 1,0]
F1-мера	0,953 [0,941; 0,963]	0,962 [0,951; 0,971]	0,326 [0,209; 0,453]	0,667 [0,543; 0,784]
Определение ротации грудной клетки на боковой проекции Determination of chest rotation on a lateral chest X-ray				
AUC	0,968 [0,962; 0,974]	0,961 [0,954; 0,968]	0,719 [0,587; 0,850]	0,898 [0,824; 0,974]
Precision	0,892 [0,880; 0,903]	0,934 [0,922; 0,945]	0,839 [0,704; 0,932]	1,0 [0,873; 1,0]
Recall	0,908 [0,896; 0,920]	0,885 [0,874; 0,895]	0,684 [0,574; 0,761]	0,692 [0,604; 0,692]
F1-мера	0,900 [0,888; 0,911]	0,909 [0,898; 0,920]	0,754 [0,633; 0,858]	0,818 [0,695; 0,899]

Примечание. Для каждой метрики диагностической точности указано значение 95% доверительного интервала. Жирным шрифтом выделены максимальные значения метрик, полученных на тестовом и валидационном наборах данных.

Note. Each diagnostic accuracy metric has a 95% confidence interval value. Bold font indicates the maximum values of the metrics obtained on the test and validation datasets.





Рис. 2. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении проекции на рентгенограммах ОГК для тестового набора данных.

Fig. 2. ROC-curves. **a** – for ResNet152V2; **b** – for VGG19 when determining the projection on the chest X-ray for the test dataset.

ROC-кривые для валидационного набора данных, содержащего 150 рентгенограмм ОГК, представлены на рис. 3. Качество классификации у моделей VGG19 и ResNet152V2 достоверно не отличается, но у модели VGG19 наблюдается тенденция к более высоким значениям метрик классификации (абсолютные значения метрик у модели VGG19 выше, но ширина доверительных интервалов не позволяет сделать вывод о достоверности различий). Модель VGG19 достаточно хорошо выполнила поставленную задачу классификации, но допустила 3 классификационные ошибки. Данные ошибки были связаны с тем, что на неверно классифицированных изображениях легкие позиционировались несколько отлично от позиционирования в обучающих данных. (Изображения в боковой проекции, где крупные легкие прилегают к верхним границам исследования, определялись моделью как изображения в прямой проекции.

Пример изображений приведен на рис. 4.) Данную ошибку можно исправить дообучением модели на изображениях с похожим расположением легких.

Определение некорректного выбора границ исследования на прямой проекции
Метрики классификации для моделей ResNet152V2 и VGG 19 на тестовом и валидационном наборах данных приведены в таблице. ROC-кривые для тестового набора данных представлены на рис. 5.

ROC-кривые для валидационного набора данных представлены на рис. 6. В валидации участвовали только изображения, правильно классифицированные моделью определения проекции.

Несмотря на то что на тестовых данных модель VGG19 проявила себя несколько хуже, чем модель ResNet152V2 (точность 0,926 против 0,947, $p < 0,05$), при работе с валидационными данными она лучше справилась с задачей классификации (точность 0,976 против 0,827, $p < 0,05$; специ-




Рис. 3. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении проекции на рентгенограммах ОГК для валидационного набора данных.

Fig. 3. ROC-curves. **a** – for ResNet152V2; **b** – for VGG19 when determining the projection on the chest X-ray for the validation dataset.





Рис. 4. Изображения, неверно классифицированные моделью определения проекции на рентгенограммах ОГК на основе архитектуры VGG19.

Fig. 4. Images incorrectly classified by the projection definition model on the chest X-ray based on the VGG19 architecture.





Рис. 5. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении некорректного выбора границ исследования на рентгенограммах ОГК прямой проекции для тестового набора данных.

Fig. 5. ROC-curves. **a** – for ResNet152V2; **б** – for VGG19 when determining the incorrect choice of the study boundaries on the frontal chest x-ray for the test dataset.





Рис. 6. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении некорректного выбора границ исследования на прямой проекции рентгенограмм ОГК для валидационного набора данных.

Fig. 6. ROC-curves. **a** – for ResNet152V2; **б** – for VGG19 when determining the incorrect choice of the study boundaries on the frontal chest x-ray for the validation dataset.





Рис. 7. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении некорректного выбора границ исследования на рентгенограммах ОГК боковой проекции для тестового набора данных.

Fig. 7. ROC-curves. **a** – for ResNet152V2; **б** – for VGG19 when determining the incorrect choice of the study boundaries on the lateral chest x-ray for the test dataset.




Рис. 8. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении некорректного выбора границ исследования на боковой проекции рентгенограмм ОГК для валидационного набора данных.

Fig. 8. ROC-curves **a** – for ResNet152V2; **б** – for VGG19 when determining the incorrect choice of the study boundaries on the lateral chest x-ray for the validation dataset.

фичность 0,984 против 0,852, $p < 0,05$). Ее можно использовать для определения обрезки границ легких с высокой точностью.

Определение некорректного выбора границ исследования на боковой проекции

Метрики классификаций для моделей ResNet152V2 и VGG 19 на тестовом и валидационном наборах данных приведены в таблице. ROC-кривые для тестового набора данных представлены на рис. 7.

ROC-кривые для валидационного набора данных представлены на рис. 8. В валидации участвовали только изображения, правильно классифицированные моделью определения проекции.

Модель VGG19 справилась с классификацией значительно лучше модели ResNet152V2 (AUC 0,926 против 0,621, $p < 0,05$; специфичность 0,857 против 0,491, $p < 0,05$; точность 0,875 против

0,532, $p < 0,05$). Фиксация данной отрезной точки позволяет максимизировать чувствительность модели и с максимальной вероятностью определять рентгенограммы с обрезанными границами легких на боковой проекции.

Определение ротации грудной клетки на боковой проекции

Метрики классификаций для моделей ResNet152V2 и VGG 19 на тестовом и валидационном наборах данных приведены в таблице. ROC-кривые для тестового набора данных представлены на рис. 9.

ROC-кривые для валидационного набора данных представлены на рис. 10. В валидации участвовали только изображения, правильно классифицированные моделью определения проекции.

Модель VGG19 лучше справилась с задачей классификации для данной задачи, чем модель ResNet152V2 (специфичность 1,0 против 0,792,




Рис. 9. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении ротации грудной клетки на рентгенограммах ОГК боковой проекции для тестового набора данных.

Fig. 9. ROC-curves. **a** – for ResNet152V2; **b** – for VGG19 when determining of chest rotation on a lateral chest x-ray for the test dataset.




Рис. 10. ROC-кривые. **а** – для ResNet152V2; **б** – для VGG19 при определении ротации грудной клетки на боковой проекции рентгенограмм ОГК для валидационного набора данных.

Fig. 10. ROC-curves. **a** – for ResNet152V2; **b** – for VGG19 when determining of chest rotation on a lateral chest x-ray for the validation dataset.

$p < 0,05$). Высокая гетерогенность проявлений ротации и разнообразие гистограмм яркости рентгенограмм, полученных из разных медицинских организаций, усложняет получение более высоких метрик классификации. Решение этой проблемы возможно путем добавления в обучающую выборку изображений, полученных из DICOM файлов с различными исходными гистограммами яркости.

Обсуждение


Трансферное обучение нашло широкое применение в разработке алгоритмов для лучевой диагностики [20–23]. Наше исследование показало, что трансферное обучение, основанное на использовании глубоких сверточных нейронных сетей, предобученных на больших объемах изображений, не связанных с медицинской визуализацией, при условии дообучения на небольшом количестве рентгенологических изображений может эффективно использоваться для обнаружения дефектов на рентгенограммах ОГК.

Наши результаты по определению проекции на рентгенограммах ОГК аналогичны результатам, показанным А. Rajkomar и соавт., которые проде-

монстрировали классификацию рентгенограмм ОГК на фронтальную или боковую проекцию с точностью 100% (99, 73–100). При этом мы смогли добиться данного результата, используя значительно меньшее количество обучающих данных: 2005 изображений против 128 796 у А. Rajkomar и соавт.

Это исследование также демонстрирует эффективность аугментации рентгенологических изображений для повышения производительности классификации. К аналогичному выводу приходили и другие исследователи [12, 20]. В условиях ограниченного количества доступных специально отобранных рентгенограмм с наличием различных дефектов, которые использовались для обучения, мы увеличили объем обучающего набора данных, что позволило осуществить классификацию рентгенограмм с достаточно высокой точностью и избежать переобучения.

В данном исследовании мы сравнили эффективность использования двух распространенных глубоких нейросетевых архитектур ResNet152V2 и VGG19, предобученных на ImageNet, при использовании для классификации рентгенограмм ОГК. Мы выяснили, что обе эти архитектуры спо-



способны классифицировать рентгенограммы с высокой точностью, но архитектура VGG19 обладает большей обобщающей способностью, что проявилось при тестировании на независимом наборе данных. Высокая эффективность архитектуры VGG19 при работе с рентгенологическими изображениями также подтверждается работами [24, 25].

Наиболее оптимальным вариантом использования моделей контроля качества медицинских изображений, подобных предложенным нами, является их внедрение в рабочую станцию рентгенолаборанта. В случае обнаружения алгоритмом технических замечаний на полученных рентгенограммах рентгенолаборант будет оповещен об этом и сможет выполнить исследование повторно до направления его врачу-рентгенологу на описание, если это позволяет допустимая дозовая нагрузка.

Заключение

Качество рентгенологического изображения зависит от множества технических, профессиональных и организационных факторов. Однако, несмотря на это, врач-рентгенолог на рабочем месте, а особенно в современных условиях глобального применения телемедицинских технологий, должен получать на диагностическую интерпретацию минимальное количество исследований с техническими замечаниями. Помочь сформировать такие условия могут системы автоматического контроля качества рентгенологических изображений. Трансферное обучение с использованием открытых наборов данных рентгенограмм ОГК позволило создать алгоритм для определения проекции и автоматического определения ряда дефектов на рентгенограммах ОГК с высокой точностью. Максимальная точность на валидационном наборе данных была получена для модели, определяющей проекцию, AUC составил 0,996, минимальная точность: AUC 0,898 была получена для модели, определяющей ротацию грудной клетки на боковой проекции. Наши результаты показывают, что трансферное обучение может успешно использоваться для классификации рентгенологических изображений и поиска на них дефектов. При использовании на этапе дообучения наших алгоритмов локальных данных метрики диагностической точности могут улучшиться. Однако обучения даже на открытых данных достаточно для допуска к клинической валидации по условному порогу диагностической точности 0,81 [26]. При широком применении наши алгоритмы способны облегчить создание больших баз данных медицинских изображений для целей машинного и глубокого обучения и обеспечение контроля качества рентгенологических изображений, что в итоге мо-

жет положительно сказаться на работе врача-рентгенолога и качестве выполнения рентгенографических исследований.

Дополнительная информация

Работа выполнена в рамках гранта с регистрационным номером карты в системе ЕГИСУ НИОКТР: 122112400040-1

Additional Information

The article was written as part of a grant with the registration number: 122112400040-1

Участие авторов

Борисов А.А. – проведение исследования, анализ и интерпретация полученных данных, обзор публикаций по теме статьи, написание текста.

Семенов С.С. – проведение исследования, анализ и интерпретация полученных данных, написание текста.

Арзамасов К.М. – концепция и дизайн исследования, утверждение окончательного варианта статьи.

Authors' participation

Borisov A.A. – conducting research, analysis and interpretation of the obtained data, review of publications, writing text.

Semenov S.S. – conducting research, analysis and interpretation of the obtained data, writing text.

Arzamasov K.M. – concept and design of the study, approval of the final version of the article.

Список литературы


1. Kim T.K., Yi P.H., Wei J. et al. Deep learning method for automated classification of anteroposterior and postero-anterior chest radiographs. *J. Digit. Imaging.* 2019; 32 (6): 925–930. <https://doi.org/10.1007/s10278-019-00208-0>
2. Shet N., Chen J., Siegel E. Continuing challenges in defining image quality. *Pediatr. Radiol.* 2011; 41 (5): 582–589. <https://doi.org/10.1007/s00247-011-2028-0>
3. McDonald R.J., Schwartz K.M., Eckel L.J. et al. The effects of changes in utilization and technological advancements of cross-sectional imaging on radiologist workload. *Acad. Radiol.* 2015; 22 (9): 1191–1198. <https://doi.org/10.1016/j.acra.2015.05.007>
4. Willis C.E., Nishino T.K., Wells J.R. et al. Automated quality control assessment of clinical chest images. *Med. Phys.* 2018; 45 (10): 4377–4391. <https://doi.org/10.1002/mp.13107>
5. Rale A.P., Gharpure D.C., Ravindran V.R. et al. Comparison of different ANN techniques for automatic defect detection in X-Ray images. *2009 International Conference on Emerging Trends in Electronic and Photonic Devices & Systems.* 2009; 193–197. <https://doi.org/10.1109/ELECTRO.2009.5441138>
6. Морозов С.П., Кузьмина Е.С., Ледихова Н.В., Владимировский А.В., Трофименко И.А., Мокиенко О.А., Панина Е.В., Андрейченко А.Е., Омелянская О.В., Гомблевский В.А., Полищук Н.С., Шулькин И.М., Решетников Р.В. Мобилизация научно-практического потенциала службы лучевой диагностики г. Москвы в пандемию COVID-19. *Digital Diagn.* 2020. 1 (1): 5–12. <https://doi.org/10.17816/DD51043>



7. Приказ Министерства здравоохранения РФ от 30 ноября 2017 г. № 965н "Об утверждении порядка организации и оказания медицинской помощи с применением телемедицинских технологий" // base.garant.ru [Электронный ресурс]. URL: <https://base.garant.ru/71851294/>
8. Приказ Департамента здравоохранения города Москвы от 01.04.2020 №323 "О создании дистанционного референс-центра по лучевой диагностике". tele-med.ai [Электронный ресурс]. URL: <https://tele-med.ai/biblioteka-dokumentov/dzm-prikaz-01042020-323-distanc-referens-centr-ld>
9. Приказ Департамента здравоохранения города Москвы от 15.03.2018 № 183 "Об утверждении регламента организации оказания медицинской помощи по профилям "рентгенология" и "радиология" с применением телемедицинских технологий". consultant.ru [Электронный ресурс]. URL: <http://www.consultant.ru/cons/cgi/online.cgi?req=doc&base=MLAW&n=184819#vjWNo7T82RuFXi2g1>
10. Приказ Департамента здравоохранения города Москвы от 31.12.2019 №1160 "Об утверждении Регламента регистрации данных в Едином радиологическом информационном сервисе автоматизированной информационной системы города Москвы «Единая медицинская информационно-аналитическая система города Москвы»". mos.ru [Электронный ресурс]. URL: <https://www.mos.ru/dzdrav/documents/department-acts/view/233696220/>
11. Morozov S.P., Ledikhova N.V., Panina E.V. et al. Performance quality of X-ray technicians when they interact remotely with the reference center for diagnostic radiology using telemedicine technologies. *Natsional'noe Zdravookhranenie*. 2021; 2 (2): 36–46.
12. Rajkomar A., Lingam S., Taylor A.G. et al. High-Throughput Classification of Radiographs Using Deep Convolutional Neural Networks. *J. Digit. Imaging*. 2017; 30 (1): 95–101. <https://doi.org/10.1007/s10278-016-9914-9>
13. CheXpert Dataset // URL: <https://stanfordmlgroup.github.io/competitions/chexpert/> (дата обращения 23.03.2022)
14. Chest X-rays dataset. URL: <https://www.kaggle.com/datasets/raddar/chest-xrays-indiana-university> (дата обращения 26.03.2022)
15. Chest X-Ray Images (Pneumonia). URL: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia> (дата обращения 20.12.2021)
16. NIH ChestX-ray14. URL: <https://nihcc.app.box.com/v/ChestXray-NIHCC> (дата обращения 20.12.2021)
17. Приказ Департамента здравоохранения города Москвы от 25.12.2017 № 918 о регламенте регистрации данных в системе "Единый радиологический информационный сервис" в медицинских организациях государственной системы здравоохранения города Москвы". consultant.ru [Электронный ресурс]. URL: <http://www.consultant.ru/cons/cgi/online.cgi?req=doc&base=MLAW&n=183590#zudlo7TsbVSwYBM12>
18. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. 3rd Int. Conf. Learn. Represent. ICLR 2015. *Conf. Track Proc.* 2015: 1–14. <https://doi.org/10.48550/arXiv.1409.1556>
19. ROC-инструмент ГБУЗ НПКЦ ДиТ ДЗМ // URL: <https://roc-analysis.mosmed.ai/> ROC analysis tool of Scientific and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow City Health Department // URL: <https://roc-analysis.mosmed.ai/>
20. Chan H.P., Samala R.K., Hadjiiski L.M., Zhou C. Deep Learning in Medical Image Analysis. *Adv. Exp. Med. Biol.* 2020; 1213: 3–21. https://doi.org/10.1007/978-3-030-33128-3_1
21. Litjens G., Kooi T., Bejnordi B.E. et al. A survey on deep learning in medical image analysis. *Med. Image Anal.* 2017; 42: 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
22. Sahiner B., Pezeshk A., Hadjiiski L.M. et al. Deep learning in medical imaging and radiation therapy. *Med. Phys.* 2019; 46 (1): 1–36. <https://doi.org/10.1002/mp.13264>
23. Mazurowski M.A., Buda M., Saha A., Bashir M.R. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *J. Magn. Reson. Imaging*. 2019; 49 (4): 939–954. <https://doi.org/10.1002/jmri.26534>
24. Rahaman M.M., Li C., Yao Y. et al. Identification of COVID-19 samples from chest X-Ray images using deep learning: A comparison of transfer learning approaches. *J. Xray Sci. Technol.* 2020; 28 (5): 821–839. <https://doi.org/10.3233%2FXST-200715>
25. Arias-Garzon D., Alzate-Grisales J.A., Orozco-Arias S. et al. COVID-19 detection in X-ray images using convolutional neural networks. *Mach. Learn Appl.* 2021; 6: 100–138. <https://doi.org/10.1016/j.mlwa.2021.100138>
26. Morozov S.P., Vladymyrsky A.V., Klyashtorny V.G. et al. Clinical acceptance of software based on artificial intelligence technologies (radiology). arXiv preprint arXiv:1908.00381. 2019. <https://doi.org/10.48550/arXiv.1908.00381>

References

1. Kim T.K., Yi P.H., Wei J. et al. Deep learning method for automated classification of anteroposterior and postero-anterior chest radiographs. *J. Digit. Imaging*. 2019; 32 (6): 925–930. <https://doi.org/10.1007/s10278-019-00208-0>
2. Shet N., Chen J., Siegel E. Continuing challenges in defining image quality. *Pediatr. Radiol.* 2011; 41 (5): 582–589. <https://doi.org/10.1007/s00247-011-2028-0>
3. McDonald R.J., Schwartz K.M., Eckel L.J. et al. The effects of changes in utilization and technological advancements of cross-sectional imaging on radiologist workload. *Acad. Radiol.* 2015; 22 (9): 1191–1198. <https://doi.org/10.1016/j.acra.2015.05.007>
4. Willis C.E., Nishino T.K., Wells J.R. et al. Automated quality control assessment of clinical chest images. *Med. Phys.* 2018; 45 (10): 4377–4391. <https://doi.org/10.1002/mp.13107>
5. Rale A.P., Gharpure D.C., Ravindran V.R. et al. Comparison of different ANN techniques for automatic defect detection in X-Ray images. *2009 International Conference on Emerging Trends in Electronic and Photonic Devices & Systems*. 2009; 193–197. <https://doi.org/10.1109/ELECTRO.2009.5441138>
6. Morozov S.P., Kuzmina E.S., Ledikhova N.V., Vladymyrsky A.V., Trofimenko I.A., Mokienko O.A., Panina E.V., Andreychenko A.E., Omelyanskaya O.V., Gombolevskiy V.A., Polishchuk N.S., Shulkin I.M., Reshetnikov R.V. Mobilizing the academic and practical potential of diagnostic radiology during the COVID-19 pandemic in Moscow. *Digital Diagnostics*. 2020; 1 (1): 5–11. <https://doi.org/10.17816/DD51043> (In Russian)
7. Order of the Ministry of Health of the Russian Federation of November 30, 2017 N 965n "About approval of the procedure for organizing and providing medical care using telemedicine technologies" base.garant.ru [Electronic



- resource]. URL: <https://base.garant.ru/71851294/> (In Russian)
8. Order of the Department of Health of the Moscow city of April 1, 2020 №323 "About the creation of a remote radiodiagnosis reference center" // tele-med.ai [Electronic resource]. URL: <https://tele-med.ai/biblioteka-dokumentov/dzm-prikaz-01042020-323-distanc-referens-centr-ld> (In Russian)
 9. Order of the Department of Health of the Moscow city of March 15, 2018 № 183 "About approval of the regulations for the organization of the provision of medical care in the profiles "roentgenology" and "radiology" using telemedicine technologies" // consultant.ru [Electronic resource]. URL : <http://www.consultant.ru/cons/cgi/online.cgi?req=doc&base=MLAW&n=184819#vjWHO7T82RuFXi2g1> (In Russian)
 10. Order of the Department of Health of the Moscow city of December 31, 2019 №1160 "About approval of the Regulations for Data Registration in the Unified Radiological Information Service of the Automated Information System of the Moscow city "Unified Medical Information and Analytical System of the Moscow City"". mos.ru [Electronic resource]. URL: <https://www.mos.ru/dzdrav/documents/department-acts/view/233696220/> (In Russian)
 11. Morozov S.P., Ledikhova N.V., Panina E.V. et al. Performance quality of X-ray technicians when they interact remotely with the reference center for diagnostic radiology using telemedicine technologies. *Natsional'noe Zdravookhranenie*. 2021; 2 (2): 36–46.
 12. Rajkomar A., Lingam S., Taylor A.G. et al. High-Throughput Classification of Radiographs Using Deep Convolutional Neural Networks. *J. Digit. Imaging*. 2017; 30 (1): 95–101. <https://doi.org/10.1007/s10278-016-9914-9>
 13. CheXpert Dataset //URL: <https://stanfordmlgroup.github.io/competitions/chexpert/> (дата обращения 23.03.2022)
 14. Chest X-rays dataset. URL: <https://www.kaggle.com/datasets/raddar/chest-xrays-indiana-university> (дата обращения 26.03.2022)
 15. Chest X-Ray Images (Pneumonia). URL: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia> (дата обращения 20.12.2021)
 16. NIH ChestX-ray14. URL: <https://nihcc.app.box.com/v/ChestXray-NIHCC> (дата обращения 20.12.2021)
 17. Order of the Department of Health of the Moscow city of December 25, 2017 № 918 "About the regulation of registration of data in the system "United radiological information service" in medical organizations of the state health system of the Moscow city" // consultant.ru [Electronic resource]. URL: <http://www.consultant.ru/cons/cgi/online.cgi?req=doc&base=MLAW&n=183590#zudlo7TsbVSwYBM12> (In Russian)
 18. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. 3rd Int. Conf. Learn. Represent. ICLR 2015. *Conf. Track Proc.* 2015: 1–14. <https://doi.org/10.48550/arXiv.1409.1556>
 19. ROC-инструмент ГБУЗ НПКЦ ДИТ ДЗМ // URL: <https://roc-analysis.mosmed.ai/> ROC analysis tool of Scientific and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow City Health Department // URL: <https://roc-analysis.mosmed.ai/>
 20. Chan H.P., Samala R.K., Hadjiiski L.M., Zhou C. Deep Learning in Medical Image Analysis. *Adv. Exp. Med. Biol.* 2020; 1213: 3–21. https://doi.org/10.1007/978-3-030-33128-3_1
 21. Litjens G., Kooi T., Bejnordi B.E. et al. A survey on deep learning in medical image analysis. *Med. Image Anal.* 2017; 42: 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
 22. Sahiner B., Pezeshk A., Hadjiiski L.M. et al. Deep learning in medical imaging and radiation therapy. *Med. Phys.* 2019; 46 (1): 1–36. <https://doi.org/10.1002/mp.13264>
 23. Mazurowski M.A., Buda M., Saha A., Bashir M.R. Deep learning in radiology: An overview of the concepts and a survey of the state of the art with focus on MRI. *J. Magn. Reson. Imaging*. 2019; 49 (4) : 939–954. <https://doi.org/10.1002/jmri.26534>
 24. Rahaman M.M., Li C., Yao Y. et al. Identification of COVID-19 samples from chest X-Ray images using deep learning: A comparison of transfer learning approaches. *J. Xray Sci. Technol.* 2020; 28 (5): 821–839. <https://doi.org/10.3233%2FXST-200715>
 25. Arias-Garzón D., Alzate-Grisales J.A., Orozco-Arias S. et al. COVID-19 detection in X-ray images using convolutional

Для корреспонденции*: Семенов Серафим Сергеевич – 127051 Москва, ул. Петровка, д. 24, стр. 1. НПКЦ диагностики и телемедицинских технологий ДЗ города Москвы. Тел.: +7-903-065-50-25. E-mail: s.semenov@npcmr.ru

Борисов Александр Александрович – разработчик программного обеспечения ФГАОУ ВО РНИМУ им. Н.И. Пирогова; младший научный сотрудник НПКЦ диагностики и телемедицинских технологий ДЗ города Москвы, Москва. <https://orcid.org/0000-0003-4036-5883>

Семенов Серафим Сергеевич – младший научный сотрудник сектора разработки систем внедрения медицинских интеллектуальных технологий НПКЦ диагностики и телемедицинских технологий ДЗ города Москвы, Москва. <https://orcid.org/0000-0003-2585-0864>

Арзамасов Кирилл Михайлович – канд. мед. наук, руководитель отдела медицинской информатики, радиомиики и радиогеномики НПКЦ диагностики и телемедицинских технологий ДЗ города Москвы, Москва. <https://orcid.org/0000-0001-7786-0349>

Contact*: Serafim S. Semenov – 24-1, Petrovka str., Moscow 127051, Russian Federation. Phone: +7-903-065-50-25. E-mail: s.semenov@npcmr.ru

Alexander A. Borisov – software developer of Pirogov Russian National Research Medical University; Junior Researcher of Medical Intelligent Technologies, Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department, Moscow. <https://orcid.org/0000-0003-4036-5883>

Serafim S. Semenov – Junior Researcher in the Sector of Development of Systems for the Introduction of Medical Intelligent Technologies, Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department, Moscow. <https://orcid.org/0000-0003-2585-0864>

Kirill M. Arzamasov – Cand. of Sci. (Med.), Head of the Department of Medical Informatics, Radiomics and Radiogenomics, Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department, Moscow. <https://orcid.org/0000-0001-7786-0349>