

УДК 004.932.2:616-073.75

10.25209/2079-3316-2023-14-3-95-113



Использование нейронных сетей для поиска нарушений укладки пациента на рентгенограммах органов грудной клетки

Александр Александрович **Борисов**^{1✉}, Юрий Александрович **Васильев**²,
Антон Вячеславович **Владимирский**³, Ольга Васильевна **Омелянская**⁴,
Серафим Сергеевич **Семенов**⁵, Кирилл Михайлович **Арзамасов**⁶

¹ Российский национальный исследовательский медицинский университет им. Н. И. Пирогова, Москва, Россия

¹⁻⁶ Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, Москва, Россия

✉ aleksandrborisov10650@gmail.com

Аннотация. В работе представлены результаты применения трансферного обучения глубоких сверточных нейронных сетей для задачи поиска рентгенограмм органов грудной клетки с нарушениями укладки и позиционирования пациента. Оцениваемые нейросетевые архитектуры: InceptionV3, Xception, ResNet152V2, InceptionResNetV2, DenseNet201, VGG16, VGG19, MobileNetV2, NASNetLarge. Для обучения и тестирования использовались рентгенограммы грудной клетки, полученные из открытых наборов данных и Единого радиологического информационного сервиса города Москвы. Все полученные модели имели метрики диагностической точности выше 95%, при этом модели на основе архитектур ResNet152V2, DenseNet201, VGG16, MobileNetV2 имели статистически значимо лучшие метрики, чем другие модели. Наилучшие абсолютные значения метрик показала модель ResNet152V2 (AUC=0.999, чувствительность=0.987, специфичность=0.988, общая валидность=0.988, F1 мера=0.988). Модель MobileNetV2 показала наилучшую скорость обработки одного исследования (67.8 ± 5.0 ms). Широкое использование полученных нами алгоритмов способно облегчить создание больших баз данных качественных медицинских изображений, а также оптимизировать контроль качества при выполнении рентгенографических исследований органов грудной клетки.

Ключевые слова и фразы: нейронные сети, глубокое обучение, контроль качества, рентген органов грудной клетки

Благодарности: Статья подготовлена в рамках НИОКР "Разработка платформы подготовки наборов данных лучевых диагностических исследований" (№ ЕГИСУ: 123031500003-8)

Для цитирования: Борисов А. А., Васильев Ю. А., Владимирский А. В., Омелянская О. В., Семенов С. С., Арзамасов К. М. *Использование нейронных сетей для поиска нарушений укладки пациента на рентгенограммах органов грудной клетки* // Программные системы: теория и приложения. 2023. Т. 14. № 3(58). С. 95–113. https://psta.pstiras.ru/read/psta2023_3_95-113.pdf


© Борисов А. А., Васильев Ю. А., Владимирский А. В., Омелянская О. В., Семенов С. С., Арзамасов К. М. 2023




Введение

Качество выполненного рентгенологического исследования напрямую влияет на диагностику и лечение заболеваний и является определяющим показателем при постановке диагноза и выборе тактики ведения пациента [3]. Максимальная информативность исследования может быть достигнута только при соблюдении всех установленных критериев качества [1].

Одним из важнейших критериев качества для рентгенологического исследования является правильное положение пациента. Во время укладки и позиционирования пациента при проведении рентгенографии органов грудной клетки необходимо учитывать расположение верхушек легких, реберно-диафрагмальных углов и других границ легких, чтобы быть уверенным, что они будут показаны на рентгенограмме [1]. (см. рисунок 1) Отсутствие данных анатомических зон на рентгенограмме может скрыть такие присутствующие у пациента патологические состояния как плевральный выпот, пневмоторакс и гидроторакс, образования и воспаление в приграничных зонах легких [2]. Отсутствие целостных границ легких на рентгенограмме снижает диагностические возможности как врача – рентгенолога, так и программного обеспечения на основе технологии искусственного интеллекта.



(а) обрезаны часть правого легкого и реберно-диафрагмальные синусы



(б) обрезаны верхушки легких

РИСУНОК 1. Рентгенограммы органов грудной клетки с нарушением укладки

На сегодняшний день дистанционное описание рентгенологических исследований стало неотъемлемой частью диагностической практики [4]. При такой организации диагностического процесса рентгенолаборанты выполняют сканирование пациентов без возможного контроля и консультации

со стороны врачей-рентгенологов, что делает качество исследований полностью зависимым от квалификации среднего медицинского персонала [5]. Наряду с этим, количество проводимых диагностических исследований непрерывно растет, что увеличивает нагрузку на врачей-рентгенологов и рентгенолаборантов и снижает время, уделяемое оценке качества полученных изображений [6]. Автоматизация контроля качества способна сократить число исследований с нарушением критериев качества, что будет способствовать снижению нагрузки на медицинский персонал и предотвращению дополнительной лучевой нагрузки пациента [7].

Алгоритмы глубокого обучения активно применяются в задачах классификации лучевых диагностических изображений [8]. Основным препятствием для применения глубокого обучения является ограниченная доступность больших и качественных наборов данных медицинских изображений [9]. Решением проблемы доступности медицинских данных является трансферное обучение, подразумевающее использование предварительно обученных на неспецифических изображениях сверточных нейронных сетей с дообучением на специфических медицинских изображениях [10].

Целью данного исследования было сравнение эффективности применения трансферного обучения различных типов глубоких сверточных нейросетевых структур для поиска нарушений укладки и позиционирования пациента на рентгенограммах органов грудной клетки

1. Материалы и методы

1.1. Выбор архитектур

В данном исследовании для сравнения использовались нейросетевые архитектуры, доступные для скачивания со сквозной платформы машинного обучения с открытым исходным кодом *TensorFlow 2*^(URL). Все архитектуры, представленные на платформе, были предварительно обучены на открытом наборе данных аннотированных изображений ImageNet, содержащим на данный момент более 14 миллионов изображений. Также для каждой модели известны показатели Top-1 точности и Top-5 точности при тестировании на валидационном наборе данных *ImageNet*^(URL). Top-1 точность подразумевает долю правильных предсказаний модели. Top-5 точность рассчитывается аналогично, но считается, что модель сделала верное предсказание, если искомый класс находится среди 5 наиболее вероятных классов при предсказании модели. Метрика Top-5 точность для оценки эффективности модели нам не подходит, так как

мы решаем задачу бинарной классификации, поэтому при отборе мы ориентировались на показатель Топ-1 точность. Для тестирования нами были отобраны 9 нейросетевых архитектур. Критерием отбора являлось максимальное значение показателя Топ-1 точность среди представителей данного типа архитектуры по данным *TensorFlow Keras Applications*^{URL}:

InceptionV3: Данная архитектура разработана в 2015 году и является разновидностью нейронных сетей Inception. Она содержит 23.9 миллиона параметров, имеет глубину 189 слоев и Топ-1 точность 77.9%. Особенностью данной архитектуры является разложение операции свертки с размером ядра $n \times n$ на набор операций свертки с размером ядра $1 \times n$ и $n \times 1$, что позволяет достичь углубления, увеличения нелинейности сети и ускорения вычислений [11].

Xception: Данная архитектура разработана в 2016 году и является усовершенствованным аналогом сети InceptionV3 за счет введения разделяемой по глубине свертки. Она содержит 22.9 миллиона параметров, имеет глубину 81 слой и Топ-1 точность 79% [12].

ResNet152V2: Архитектура ResNet разработана в 2015 году и смогла решить проблему исчезающего градиента при обучении глубоких нейронных сетей. Особенностью является эффективное соединение выходных данных разных слоев, что позволяет лучше извлекать многомерные характеристики изображения. ResNet152V2 содержит 60.4 миллиона параметров, имеет глубину 307 слоев и Топ-1 точность 78% [13].

InceptionResNetV2: Данная архитектура разработана в 2016 году и является усовершенствованным аналогом сети InceptionV3 с добавлением связей между выходными данными разных слоев как у ResNet. Она содержит 55.9 миллиона параметров, имеет глубину 449 слоев и Топ-1 точность 80.3% [14].

DenseNet201: Архитектура DenseNet является потомком архитектуры ResNet. Ее особенностью является более “плотная” связь между слоями, при которой каждый слой объединяет входные данные всех предыдущих слоев и передает выходные данные каждого слоя всем последующим слоям. DenseNet201 содержит 20.2 миллиона параметров, имеет глубину 402 слоя и Топ-1 точность 77.3% [15].

VGG19 и *VGG16*: Архитектура VGG появилась в 2014 году. Ее особенностью являлось замена больших фильтров свертки на последовательные свертки с маленькими фильтрами (3x3), что значительно упрощало математические вычисления. У сетей VGG19 и VGG16 одинаковая заявленная Топ-1 точность – 71.3%, поэтому мы протестировали в нашей задаче обе архитектуры. Количество параметров 143.7 и 138.4, количество слоев 19 и 16 соответственно [16].

MobileNetV2: Архитектура MobileNet появилась в 2018 году и произвела фурор, существенно снизив количество параметров и вес нейронной сети, позволив активно использовать нейронные сети на мобильных платформах. Отличительной особенностью от MobileNetV1 является наличие свёртки 1x1 с линейной функцией активации, которая понижает число каналов. MobileNetV2 содержит 3.5 миллиона параметров, имеет глубину 105 слоев и Топ-1 точность 71.3% [17].

NASNetLarge: Архитектура NASNetLarge использует метод поиска с подкреплением, чтобы найти лучшие конфигурации архитектуры. Она состоит из редуцированных и нормальных слоев свертки. Слои редукции — это ячейки свертки, которые возвращают карту признаков с ее двукратным уменьшением. NASNetLarge содержит 88.9 миллиона параметров, имеет глубину 533 слоев и Топ-1 точность 82.5% [18].

1.2. Подготовка данных

Для дообучения выбранных архитектур использовался набор данных из 10734 рентгенограмм органов грудной клетки (РГ ОГК). Из них 5182 РГ ОГК без нарушения укладки и 5552 РГ ОГК с различными нарушениями укладки. Для тестирования моделей использовался набор данных из 2347 РГ ОГК, из них 1096 РГ ОГК без нарушения укладки и 1251 РГ ОГК с различными нарушениями укладки. Для формирования указанных наборов данных использовались отобранные вручную рентгенограммы из открытых наборов данных *CheXpert*^{URL} [8], *Chest X-rays*^{URL}, *PadChest*^{URL} в количестве 6682 рентгенограмм, а также рентгенограммы выгруженные из Единого радиологического информационного сервиса Единой медицинской информационно-аналитической системы города Москвы (ЕРИС ЕМИАС) и конвертированные из формата DICOM в формат PNG в количестве 6399 рентгенограмм.

1.3. Условия обучения и тестирования

Для объективного сравнения различных архитектур было решено создать одинаковые условия для обучения. Были сформированы одинаковые по наполнению тестовые и валидационные наборы данных для каждой модели. Для всех архитектур были выбраны: количество эпох обучения -20, размер батча – 64 изображения, размер входного изображения 244x244 пикселя. У каждой архитектуры замораживались внутренние веса, удалялся классификационный слой и добавлялся единый для всех архитектур блок классификации:

- выравнивающий (Flatten) слой
- полносвязный слой из 512 нейронов с функцией активации ReLu
- слой исключения (Dropout), обнуляющий 20% весов
- полносвязный слой из 512 нейронов с функцией активации ReLu
- слой исключения (Dropout), обнуляющий 20% весов
- полносвязный слой из 1 нейрона с функцией активации sigmoid

Обучение и тестирование проводились на персональном компьютере: OS Windows 10, CPU: Intel Core i7-10875H (8 ядер), RAM: 16 Gb, язык программирования Python 3.8, среда: Jupyter Notebook.

Качество работы обученных моделей оценивалось на этапе обучения при помощи метрик: общая валидность (accuracy), чувствительность (recall), ПЦПР - прогностическая ценность положительного результата (precision), функции потерь основанной на бинарной кросс-энтропии. Для объективной оценки обученные модели также оценивали на тестовой отложенной (не участвующей в обучении) выборки при помощи стандартных метрик диагностической точности: чувствительность, специфичность, общая валидность, площадь под характеристической кривой с расчетом 95% доверительных интервалов методом DeLong. Порог отсека для бинаризации выбирался при помощи максимизации индекса Юдена. Данные метрики получены с использованием *открытого отечественного инструмента ROC-анализа из ГБУЗ НПКЦ ДнТ ДЗМ*^{[URL](#)}. Помимо этого, для каждой модели рассчитывалась F1 мера и определялось время обработки 1 исследования из тестовой выборки в формате среднее арифметическое \pm стандартное отклонение.

Решение о достоверности различий между значениями метрик классификации разных моделей определялось на основании не пересечения 95% доверительных интервалов соответствующих метрик. Утверждение о том, что одна модель справилась с задачей классификации лучше, чем другая принималось, если существовали достоверные различия по нескольким или всем метрикам классификации между данными моделями.

2. Результаты

Все выбранные архитектуры были развернуты на персональном компьютере и обучены на подготовленном наборе данных. Ниже для каждой исследуемой архитектуры приведены метрики диагностической точности, полученные на этапе обучения и ROC-кривые, полученные на тестовом наборе данных.

InceptionV3: Модель прошла обучение в течение 20 эпох. Метрики, полученные на обучающей выборке: функция потерь: 0.2217, общая валидность: 0.9109, чувствительность: 0.9038, ПЦПР: 0.9224.

Xception: Модель прошла обучение в течение 20 эпох. Метрики, полученные на обучающей выборке: функция потерь: 0.1160, общая валидность: 0.9555, чувствительность: 0.9570, ПЦПР: 0.9570.

ResNet152V2: Модель прошла обучение в течение 16 эпох. После 16 эпохи пошло переобучение модели, поэтому были сохранены веса последней эпохи. Метрики, полученные на обучающей выборке: функция потерь: 0.0999, общая валидность: 0.9633, чувствительность: 0.9625, ПЦПР: 0.9664.

InceptionResNetV2: Модель прошла обучение в течение 20 эпох. Метрики, полученные на обучающей выборке: функция потерь: 0.1867, общая валидность: 0.9259, чувствительность: 0.9277, ПЦПР: 0.9289.

DenseNet201: Модель прошла обучение в течение 19 эпох. После 19 эпохи пошло переобучение модели, поэтому были сохранены веса последней эпохи. Метрики, полученные на обучающей выборке: функция потерь: 0.0671, общая валидность: 0.9733, чувствительность: 0.9775, ПЦПР: 0.9710.

VGG16: Модель прошла обучение в течение 13 эпох. После 13 эпохи пошло переобучение модели, поэтому были сохранены веса последней эпохи. Метрики, полученные на обучающей выборке: функция потерь: 0.0897, общая валидность: 0.9651, чувствительность: 0.9663, ПЦПР: 0.9663.

VGG19: Модель прошла обучение в течение 10 эпох. После 10 эпохи пошло переобучение модели, поэтому были сохранены веса последней эпохи. Метрики, полученные на обучающей выборке: функция потерь: 0.1490, общая валидность: 0.9415, чувствительность: 0.9502, ПЦПР: 0.9375.

MobileNetV2: Модель прошла обучение в течение 20 эпох. Метрики, полученные на обучающей выборке: функция потерь: 0.0684, общая валидность: 0.9723, чувствительность: 0.9684, ПЦПР: 0.9777.

NASNetLarge: Модель прошла обучение в течение 20 эпох. Метрики, полученные на обучающей выборке: функция потерь: 0.1482, общая валидность: 0.9419, чувствительность: 0.9385, ПЦПР: 0.9486.

На втором этапе было проведено тестирование ранее обученных моделей на отложенном тестовом наборе данных с целью объективной оценки эффективности решения задачи классификации. Сводные результаты тестирования на тестовом наборе данных из 2347 РГ ОГК представлены в таблице 1.

Таблица 1. Метрики диагностической точности на тестовой выборке (жирным шрифтом выделены максимальные значения каждой метрики)

Модель	AUC	F1 score	Чувствительность	Специфичность	Общая валидность	Время обработки 1 исследования
<i>InceptionV3</i>	0.992 [0.989;0.994]	0.955 [0.948;0.962]	0.949 [0.937;0.961]	0.957 [0.945;0.969]	0.953 [0.944;0.961]	73.6 ± 8.7 ms
<i>Xception</i>	0.995 [0.994;0.997]	0.969 [0.964;0.975]	0.966 [0.956;0.976]	0.97 [0.96;0.98]	0.968 [0.96;0.975]	121 ± 22 ms
<i>ResNet152V2</i>	0.999 [0.998;1.0]	0.988 [0.985;0.992]	0.987 [0.981;0.993]	0.988 [0.982;0.995]	0.988 [0.983;0.992]	153.2 ± 9.9 ms
<i>InceptionResNetV2</i>	0.993 [0.991;0.996]	0.967 [0.961;0.973]	0.961 [0.95;0.972]	0.97 [0.96;0.98]	0.965 [0.958;0.972]	359 ± 30 ms
<i>DenseNet201</i>	0.998 [0.997;0.979]	0.985 [0.98;0.989]	0.99 [0.984;0.995]	0.977 [0.968;0.986]	0.984 [0.979;0.9889]	131 ± 6.6 ms
<i>VGG16</i>	0.998 [0.997;0.989]	0.981 [0.977;0.986]	0.978 [0.97;0.9886]	0.982 [0.974;0.989]	0.98 [0.974;0.9886]	90 ± 3.5 ms
<i>VGG19</i>	0.994 [0.992;0.986]	0.964 [0.957;0.97]	0.961 [0.95;0.972]	0.965 [0.954;0.976]	0.963 [0.955;0.971]	110 ± 5.1 ms
<i>MobileNetV2</i>	0.998 [0.997;0.999]	0.978 [0.973;0.982]	0.98 [0.972;0.988]	0.975 [0.966;0.985]	0.978 [0.972;0.984]	67.8 ± 5.0 ms
<i>NASNetLarge</i>	0.992 [0.989;0.994]	0.957 [0.95;0.963]	0.945 [0.932;0.957]	0.97 [0.96;0.98]	0.957 [0.948;0.965]	371 ± 29 ms

Согласно результатам, полученным на тестовой выборке, архитектуры ResNet152V2, DenseNet201, VGG16, MobileNetV2 по всем или ряду метрик превосходят архитектуры InceptionV3, Xception, InceptionResNetV2, VGG19, NASNetLarge ($p < 0.05$). Между собой метрики, полученные архитектурами ResNet152V2, DenseNet201, VGG16, MobileNetV2, статистически значимо не различаются ($p > 0.05$), при этом модель на основе архитектуры ResNet152V2 показывает тенденцию к более высоким абсолютным значениям ROC AUC, F1 меры, специфичности и общей валидности, а модель на основе архитектуры DenseNet201 показывает тенденцию к более высокому абсолютному значению чувствительности. Однако, одной из важнейших характеристик для глубоких нейронных сетей является время, затраченное на шаг вывода данных. В нашем исследовании наилучшее время вывода показала модель на основе архитектуры MobileNetV2. При этом MobileNetV2 тратит времени на шаг вывода данных на 24.6% меньше чем VGG16, на 48.4% меньше чем DenseNet201 и на 55.7% меньше чем ResNet152V2.

3. Обсуждение

Наше исследование показало, что трансферное обучение глубоких нейросетевых архитектур способно с высокой точностью классифицировать рентгенологические изображения, в том числе решить задачу определения нарушений укладки пациента на рентгенограммах органов грудной клетки. Все полученные нами модели имеют метрики диагностической точности выше 95%, что превышает условный порог для допуска к клинической валидации в 81% [19]. Эффективность нейросетевых архитектур, получивших в нашем исследовании наилучшие показатели (ResNet152V2 и MobileNetV2), подтверждается зарубежными коллегами, использовавшими их в рамках своих исследований [20–23].

Нам удалось улучшить наши собственные результаты по определению нарушения укладки и позиционирования пациента на РГ ОГК прямой проекции, полученные ранее, [24] за счет использования, помимо открытых наборов данных, локальные данные (рентгенограммы выгруженные из Единого радиологического информационного сервиса Единой медицинской информационно-аналитической системы города Москвы). При этом мы использовали меньшее количество изображений для обучения - 10734 РГ ОГК против 13580 РГ ОГК. Это свидетельствует о том, что на точность обученного программного обеспечения (ПО) на основе технологии искусственный интеллект (ТИИ) могут сильно влиять разнообразие данных, используемых при разработке. Это могут

быть: демографические особенности исследуемого населения, настройки диагностической аппаратуры, клинический профиль учреждения в котором получены изображения, способы конвертации форматов, нормализации и эквализации изображений. Наши выводы согласуются с утверждениями, выдвинутыми Европейским Обществом Радиологов [26]. Так мы показали, что AUC, полученный в ходе нашего предыдущего исследования для модели на основе архитектуры ResNet152V2 был повышен с 0.866 до 0.999, что говорит о существенном улучшении классификационной точности модели (см. таблицу 2) [24]. Обобщающая способность (генерализуемость) алгоритма в составе ПО на основе ТИИ будет выше, чем шире вариативность медицинских устройств и организаций, используемых при формировании наборов данных.

Таблица 2. Сравнение метрик диагностической точности для модели ResNet152V2 с разными источниками обучающих данных

Модель обучена	исключительно на открытых данных	на комбинации открытых данных и данных из ЕРИС ЕМИАС
AUC	0.866[0.779;0.954]	0.999[0.998;1.0]
Чувствительность	0.750[0.560;0.940]	0.987[0.981;0.993]
Специфичность	0.852[0.763;0.941]	0.988[0.982;0.995]
Общая валидность	0.827[0.745;0.910]	0.988[0.983;0.992]
F1-мера	0.682[0.566; 0.779]	0.988[0.985;0.992]

Наши результаты использования глубоких сверточных нейронных сетей для определения нарушения укладки и позиционирования пациента на РГ ОГК в прямой проекции превосходят результаты алгоритма Whaley и соавт., основанного на определении геометрических характеристик на изображении. В своем исследовании они столкнулись с низкой специфичностью, полученного алгоритма, описывавшего больше дефектных исследований, чем технологи [25].

Созданные нами модели можно использовать как для автоматической разметки изображений при формировании больших наборов данных, так и в качестве средства поддержки принятия решений рентгенолаборанта, оповещающая его о наличии нарушения укладки и позиционирования на исследовании, что позволит ему с учетом допустимой дозовой нагрузки выполнить исследование повторно, до направления его врачу-рентгенологу на описание.

Заключение

Нами проведено трансферное обучение и тестирование 9 нейросетевых архитектур для поиска нарушений укладки пациента на рентгенограммах органов грудной клетки. Все полученные нами модели имеют метрики диагностической точности выше 95%, что позволяет использовать их в клинической практике. По результатам нашего исследования можно выделить 2 наилучшие архитектуры для решения поставленной задачи: в условиях ограниченного времени на обработку исследований стоит использовать архитектуру MobileNetV2, имеющую наименьшее время на шаг вывода данных (67.8 ± 5.0 ms), в условиях неограниченного времени стоит использовать архитектуру ResNet152V2, имеющую наибольшие абсолютные значения метрик качества (AUC=0.999, чувствительность=0.987, специфичность=0.988, общая валидность=0.988, F1 мера=0.988). Широкое использование полученных нами алгоритмов способно облегчить создание больших наборов данных качественных медицинских изображений, а также оптимизировать контроль качества при выполнении рентгенографических исследований органов грудной клетки.

Список использованных источников

- [1] Lampignano J., Bontrager K. L. *Textbook of Radiographic Positioning and Related Anatomy*, 8th edition.– St. Louis (Mo.): Elsevier Mosby.– 2014.– ISBN 978-0323083881.– 848 pp. [↑](#)₉₆
- [2] Broder J. *Imaging the chest: the chest radiograph // Diagnostic Imaging for the Emergency Physician*, chapter 5.– Elsevier.– 2011.– ISBN 978-1-4160-6113-7.– Pp. 185–296. [doi](#) [↑](#)₉₆
- [3] Wang J., Li Zh., Pu L., Zhang K., Liu X., Zhou B. *Research and application of orthotopic DR chest radiograph quality control system based on artificial intelligence // Journal of Biomedical Engineering*.– 2020.– Vol. **37**.– No. 1.– Pp. 158–168. [doi](#) [↑](#)₉₆
- [4] 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., Гомболевский 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 Diagnostics*.– 2020.– Т. **1**.– № 1.– С. 5–11. [doi](#) [↑](#)₉₆
- [5] Морозов С. П., Ледихова Н. В., Панина Е. В., Владимировский А. В., Фомичева Е. П. *Качество работы рентгенолаборантов в условиях дистанционного взаимодействия с референс-центром лучевой диагностики с применением телемедицинских технологий // Национальное здравоохранение*.– 2021.– Т. **2**.– № 2.– С. 36–46. [doi](#) [↑](#)₉₇
- [6] van Leeuwen K. G., de Rooij M., Schalekamp S., van Ginneken B., Rutten M. J. C. M. *How does artificial intelligence in radiology improve efficiency and health outcomes?* *Pediatr. Radiol.*– 2022.– Vol. **52**.– No. 11.– Pp. 2087–2093. [doi](#) [↑](#)₉₇

- [7] Willis Ch. E., Nishino T. K., Wells J. R., Ai H. A., Wilson J. M., Samei E. *Automated quality control assessment of clinical chest images* // Med. Phys.– 2018.– Vol. **45**.– No. 10.– Pp. 4377–4391. doi ↑97
- [8] Miotto R., Wang F., Wang Sh., Jiang X., Dudley J. T. *Deep learning for healthcare: review, opportunities and challenges* // Brief Bioinform.– 2018.– Vol. **19**.– No. 6.– Pp. 1236–1246. doi ↑97, 99
- [9] Usman M., Zia T., Tariq A. *Analyzing transfer learning of vision transformers for interpreting chest radiography* // J. Digit. Imaging.– 2022.– Vol. **35**.– No. 6.– Pp. 1445–1462. doi ↑97
- [10] Kim H. E., Cosa-Linan A., Santhanam N., Jannesari M., Maros M. E., Ganslandt T. *Transfer learning for medical image classification: a literature review* // BMC Med. Imaging.– 2022.– Vol. **22**.– id. 69.– 13 pp. doi ↑97
- [11] Szegedy Ch., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. *Rethinking the inception architecture for computer vision*, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (Las Vegas, NV, USA, 27–30 June 2016).– 2016.– Pp. 2818–2826. doi ↑98
- [12] Chollet F. *Xception: deep learning with depthwise separable convolutions*, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (Honolulu, HI, USA, 21–26 July 2017).– 2017.– Pp. 1800–1807. doi ↑98
- [13] He K., Zhang X., Ren S., Sun J. *Identity mappings in deep residual networks*, Computer Vision – ECCV 2016 (Amsterdam, The Netherlands, October 11–14, 2016), Lecture Notes in Computer Science.– vol. **9908**, eds. Leibe B., Matas J., Sebe N., Welling M., Cham: Springer.– 2016.– ISBN 978-3-319-46493-0.– Pp. 630–645. doi ↑98
- [14] Szegedy Ch., Ioffe S., Vanhoucke V., Alemi A. *Inception-v4, inception-ResNet and the impact of residual connections on learning* (San Francisco, California, 2017) // Proceedings of the AAAI Conference on Artificial Intelligence.– Vol. **31**.– No. 1, Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence AAAI 2017.– Pp. 4278–4284. doi ↑98
- [15] Huang G., Liu Z., Van Der Maaten L., Weinberger K. Q. *Densely connected convolutional networks* // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 21–26 July 2017.– 2017.– ISBN 978-1-5386-0457-1.– Pp. 2261–2269. doi ↑98
- [16] Liu S., Deng W. *Very deep convolutional neural network based image classification using small training sample size*, 2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR) (Kuala Lumpur, Malaysia, 03–06 November 2015).– 2015.– Pp. 730–734. doi ↑98
- [17] Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.-C. *MobileNetV2: inverted residuals and linear bottlenecks*, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (Salt Lake City, UT, USA, 18–23 June 2018).– 2018.– Pp. 4510–4520. doi ↑99
- [18] Zoph B., Vasudevan V., Shlens J., Le Q. V. *Learning transferable architectures for scalable image recognition* // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (Salt Lake City, UT, USA, 18–23 June 2018).– 2018.– Pp. 8697–8710. doi ↑99

- [19] Морозов С. П., Владимировский А. В., Кляшторный В. Г., Андрейченко А. Е., Кульберг Н. С., Гомболевский В. А. *Клинические испытания программного обеспечения на основе интеллектуальных технологий (лучевая диагностика)*, Препринт № ЦДТ-2019-1.– М.– 2019.– 34 с. [URL](#) ↑¹⁰³
- [20] Kanjanasurat I., Tenghongsakul K., Purahong B., Lasakul A. *CNN-RNN Network Integration for the Diagnosis of COVID-19 Using Chest X-ray and CT Images* // *Sensors* (Basel).– 2023.– Vol. **23**.– No. 3.– id. 1356.– 12 pp. [doi](#) ↑¹⁰³
- [21] Baccouche A., Garcia-Zapirain B., Elmaghraby A. S. *An integrated framework for breast mass classification and diagnosis using stacked ensemble of residual neural networks* // *Sci. Rep.*– 2022.– Vol. **12**.– No. 1.– id. 12259.– 17 pp. [doi](#) ↑¹⁰³
- [22] Nguyen T., Do T. H., Pham Q. D. *A deep learning based system for Covid-19 positive cases detection using chest X-ray images* // *Proceedings of the 2022 13th International Conference on Information and Communication Technology Convergence (ICTC)* (Jeju Island, Republic of Korea, 19–21 October 2022).– Pp. 1082–1087. [doi](#) ↑¹⁰³
- [23] Liu Z., Liu Y., Zhang W., Hong Y., Meng J., Wang J., Zheng Sh., Xu X. *Deep learning for prediction of hepatocellular carcinoma recurrence after resection or liver transplantation: a discovery and validation study* // *Hepatol. Int.*– 2022.– Vol. **16**.– No. 3.– Pp. 577–589. [doi](#) ↑¹⁰³
- [24] Борисов А. А., Семенов С. С., Арзамасов К. М. *Использование трансферного обучения для автоматизированного поиска дефектов на рентгенограммах органов грудной клетки* // *Медицинская визуализация*.– Т. **27**.– № 1.– С. 158–169. [doi](#) ↑^{103, 104}
- [25] Whaley J. S., Pressman B. D., Wilson J. R., Bravo L., Sehnert W. J., Foos D. H. *Investigation of the variability in the assessment of digital chest X-ray image quality* // *J. Digit. Imaging*.– 2013.– Vol. **26**.– No. 2.– Pp. 217–226. [doi](#) ↑¹⁰⁴
- [26] European Society of Radiology (ESR) *What the radiologist should know about artificial intelligence — an ESR white paper* // *Insights Imaging*.– 2019.– Vol. **10**.– No. 1.– id. 44. [doi](#) ↑¹⁰⁴

Поступила в редакцию	15.04.2023;
одобрена после рецензирования	05.05.2023;
принята к публикации	18.06.2023;
опубликована онлайн	07.10.2023.

Рекомендовал к публикации


к.т.н. Я. И. Гулиев

Информация об авторах:



Александр Александрович Борисов

Младший научный сотрудник отдела медицинской информатики, радиомики и радиогеномики НПКЦ диагностики и телемедицинских технологий ДЗМ, Москва. Аналитик ИЦТМ ФГАОУ ВО РНИМУ им. Н.И. Пирогова, Москва. Научные интересы: лучевая диагностика, компьютерное зрение в области обработки медицинских изображений, машинное обучение, нейронные сети, оценка качества диагностических исследований


 0000-0003-4036-5883

e-mail: aleksandrborisov10650@gmail.com



Юрий Александрович Васильев

к.м.н, директор НПКЦ диагностики и телемедицинских технологий ДЗМ. Главный внештатный специалист по лучевой и инструментальной диагностике ДЗМ, член правления Московского регионального отделения Российского общества рентгенологов и радиологов. Научные интересы: оказание медицинской помощи с применением цифровых технологий, технологии искусственного интеллекта в диагностике

 0000-0002-0208-5218

e-mail: VasilevYA1@zdrav.mos.ru



Антон Вячеславович Владимирский

д.м.н., заместитель директора по научной работе НПКЦ диагностики и телемедицинских технологий ДЗМ. Научные интересы: доказательная телемедицина, организация и оказание медицинской помощи с применением цифровых (информационных) технологий, методология оценки качества телемедицинских технологий, эффективность телемедицины в клинических дисциплинах, методология оценки качества и точности алгоритмов искусственного интеллекта, история телемедицины.

 0000-0002-2990-7736

e-mail: VladimirskijAV@zdrav.mos.ru



Ольга Васильевна Омелянская

Руководитель по управлению подразделениями Дирекции наука НПКЦ диагностики и телемедицинских технологий ДЗМ. Научные интересы: оказание медицинской помощи с применением цифровых технологий, технологии искусственного интеллекта в диагностике


 0000-0002-0245-4431

e-mail: OmelyanskayaOV@zdrav.mos.ru



Серафим Сергеевич Семенов

врач-рентгенолог, младший научный сотрудник сектора разработки систем внедрения медицинских интеллектуальных технологий НПКЦ диагностики и телемедицинских технологий ДЗМ. Научные интересы: радиомика, текстурный анализ изображений, информационные технологии в медицине, технологии искусственного интеллекта и компьютерное зрение в диагностике


 0000-0003-2585-0864

e-mail: SemenovSS3@zdrav.mos.ru



Кирилл Михайлович Арзамасов

к.м.н., руководитель отдела медицинской информатики, радиомики и радиогеномики НПКЦ диагностики и телемедицинских технологий ДЗМ. Научные интересы: системы поддержки принятия врачебных решений на базе технологии искусственного интеллекта в диагностике, системы анализа медицинских изображений в ультразвуковой и лучевой диагностике, телемедицинские диагностические системы, носимые устройства мониторинга сердечно-сосудистой системы

 0000-0001-7786-0349

e-mail: ArzamasovKM@zdrav.mos.ru

Все авторы сделали эквивалентный вклад в подготовку публикации.

Декларация об отсутствии личной заинтересованности: благополучие авторов не зависит от результатов исследования.



Using of neural networks to search for errors of patient's positioning on chest X-rays

Alexander Aleksandrovich **Borisov**^{1✉}, Yuri Aleksandrovich **Vasiliev**²,
Anton Vyacheslavovich **Vladimirsky**³, Olga Vasil'evna **Omelyanskaya**⁴,
Serafim Sergeevich **Serafim**⁵, Kirill Mikhailovich **Arzamasov**⁶

¹⁻⁶Scientific and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Department of Health, Moscow, Russia

¹Progov Russian National Research Medical University, Moscow, Russia

[✉]aleksandrborisov10650@gmail.com

Abstract. The paper presents the results of the application of transfer learning of deep convolutional neural networks for the task of searching for chest X-rays with errors of patient styling and positioning. Evaluated neural network architectures: InceptionV3, Xception, ResNet152V2, InceptionResnetV2, DenseNet201, VGG16, VGG19, MobileNetV2, NASNetLarge. For training and testing we used chest X-rays from open datasets and the unified radiological information service of the city of Moscow. All the models obtained had diagnostic accuracy metrics above 95%, while models based on the ResNet152V2, DenseNet201, VGG16, MobileNetV2 architectures had statistically significantly better metrics than other models. The best absolute values of metrics were shown by the ResNet152V2 model (AUC=0.999, sensitivity=0.987, specificity=0.988, accuracy=0.988, F1 score=0.988). The MobileNetV2 model showed the best processing speed of one study (67.8 ± 5.0 ms). The widespread use of the algorithms we have obtained can facilitate the creation of large databases of high-quality medical images, as well as optimize quality control when performing chest X-ray examinations. (*In Russian*).

Key words and phrases: neural networks, deep learning, quality control, chest X-ray

2020 *Mathematics Subject Classification:* 68T07; 68U10, 92C50

Acknowledgments: The article was prepared within the framework of RD "Development of a platform for preparing data sets of radiation diagnostic studies" (EGISU No.: 123031500003-8)

For citation: Alexander A. Borisov, Yuri A. Vasiliev, Anton V. Vladimirsky, Olga V. Omelyanskaya, Serafim S. Serafim, Kirill M. Arzamasov. *Using of neural networks to search for errors of patient's positioning on chest X-rays*. Program Systems: Theory and Applications, 2023, 14:3(58), pp. 95–113. (*In Russ.*). https://psta.psiras.ru/read/psta2023_3_95-113.pdf

References

- [1] J. Lampignano, Bontrager K. L. . *Textbook of Radiographic Positioning and Related Anatomy*, 8th edition, Elsevier Mosby, St. Louis (Mo.), 2014, ISBN 978-0323083881, 848 pp.
- [2] J. Broder. “Imaging the chest: the chest radiograph”, *Diagnostic Imaging for the Emergency Physician*, chapter 5, Elsevier, 2011, ISBN 978-1-4160-6113-7, pp. 185–296. [doi](#)
- [3] J. Wang, Zh. Li, L. Pu, K. Zhang, X. Liu, B. Zhou. “Research and application of orthotopic DR chest radiograph quality control system based on artificial intelligence”, *Journal of Biomedical Engineering*, **37**:1 (2020), pp. 158–168. [doi](#)
- [4] S. P. Morozov, E. S. Kuz'mina, N. V. Ledixova, A. V. Vladzimirskij, I. A. Trofimenko, O. A. Mokieenko, E. V. Panina, A. E. Andrejchenko, O. V. Omelyanskaya, V. A. Gombolevskij, N. S. Polishhuk, I. M. Shul'kin, R. V. Reshetnikov. “Mobilizing the academic and practical potential of diagnostic radiology during the COVID-19 pandemic in Moscow”, *Digital Diagnostics*, **1**:1 (2020), pp. 5–11 (in Russian). [doi](#)
- [5] S. P. Morozov, N. V. Ledixova, E. V. Panina, A. V. Vladzimirskij, E. P. Fomicheva. “Performance quality of x-ray technicians when they interact remotely with the reference center for diagnostic radiology using telemedicine technologies”, *Nacional'noe zdravooxranenie*, **2**:2 (2021), pp. 36–46 (in Russian). [doi](#)
- [6] K. G. van Leeuwen, de Rooij M., S. Schalekamp, B. van Ginneken, M. J. C. M. Rutten. How does artificial intelligence in radiology improve efficiency and health outcomes? *Pediatr. Radiol.*, **52**:11 (2022), pp. 2087–2093. [doi](#)
- [7] Ch. E. Willis, T. K. Nishino, J. R. Wells, H. A. Ai, J. M. Wilson, E. Samei. “Automated quality control assessment of clinical chest images”, *Med. Phys.*, **45**:10 (2018), pp. 4377–4391. [doi](#)
- [8] R. Miotto, F. Wang, Sh. Wang, X. Jiang, Dudley J. T. . “Deep learning for healthcare: review, opportunities and challenges”, *Brief Bioinform.*, **19**:6 (2018), pp. 1236–1246. [doi](#)
- [9] M. Usman, T. Zia, A. Tariq. “Analyzing transfer learning of vision transformers for interpreting chest radiography”, *J. Digit. Imaging*, **35**:6 (2022), pp. 1445–1462. [doi](#)
- [10] H. E. Kim, A. Cosa-Linan, N. Santhanam, Jannesari M. , M. E. Maros, T. Ganslandt. “Transfer learning for medical image classification: a literature review”, *BMC Med. Imaging*, **22** (2022), id. 69, 13 pp. [doi](#)
- [11] Ch. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna. “Rethinking the inception architecture for computer vision”, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (Las Vegas, NV, USA, 27–30 June 2016), 2016, pp. 2818–2826. [doi](#)
- [12] F. Chollet. “Xception: deep learning with depthwise separable convolutions”, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (Honolulu, HI, USA, 21–26 July 2017), 2017, pp. 1800–1807. [doi](#)

- [13] K. He, X. Zhang, S. Ren, J. Sun. “Identity mappings in deep residual networks”, *Computer Vision – ECCV 2016* (Amsterdam, The Netherlands, October 11–14, 2016), Lecture Notes in Computer Science, vol. **9908**, eds. Leibe B., Matas J., Sebe N., Welling M., Springer, Cham, 2016, ISBN 978-3-319-46493-0, pp. 630–645. [doi](#)
- [14] Ch. Szegedy, S. Ioffe, V. Vanhoucke, A. Alemi. “Inception-v4, inception-ResNet and the impact of residual connections on learning” (San Francisco, California, 2017), *Proceedings of the AAAI Conference on Artificial Intelligence*, **31**:1, Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence AAAI 2017, pp. 4278–4284. [doi](#)
- [15] G. Huang, Z. Liu, Der Maaten L. Van, K. Q. Weinberger. “Densely connected convolutional networks”, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21–26 July 2017, 2017, ISBN 978-1-5386-0457-1, pp. 2261–2269. [doi](#)
- [16] S. Liu, W. Deng. “Very deep convolutional neural network based image classification using small training sample size”, 2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR) (Kuala Lumpur, Malaysia, 03–06 November 2015), 2015, pp. 730–734. [doi](#)
- [17] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, Chen L.-C. . “MobileNetV2: inverted residuals and linear bottlenecks”, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (Salt Lake City, UT, USA, 18–23 June 2018), 2018, pp. 4510–4520. [doi](#)
- [18] B. Zoph, V. Vasudevan, J. Shlens, Q. V. Le. “Learning transferable architectures for scalable image recognition”, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition* (Salt Lake City, UT, USA, 18–23 June 2018), 2018, pp. 8697–8710. [doi](#)
- [19] S. P. Morozov et al. *Clinical testing of software based on intelligent technologies (radiation diagnosis)*, Preprint No CzDT-2019-1, M., 2019 (in Russian), 53 pp. [URL](#)
- [20] I. Kanjanasurat, K. Tenghongsakul, B. Purahong, A. Lasakul. “CNN–RNN Network Integration for the Diagnosis of COVID-19 Using Chest X-ray and CT Images”, *Sensors (Basel)*, **23**:3 (2023), id. 1356, 12 pp. [doi](#)
- [21] A. Baccouche, B. Garcia-Zapirain, A. S. Elmaghraby. “An integrated framework for breast mass classification and diagnosis using stacked ensemble of residual neural networks”, *Sci. Rep.*, **12**:1 (2022), id. 12259, 17 pp. [doi](#)
- [22] T. Nguyen, T. H. Do, Q. D. Pham. “A deep learning based system for Covid-19 positive cases detection using chest X-ray images”, *Proceedings of the 2022 13th International Conference on Information and Communication Technology Convergence (ICTC)* (Jeju Island, Republic of Korea, 19–21 October 2022), pp. 1082–1087. [doi](#)
- [23] Z. Liu, Y. Liu, W. Zhang, Y. Hong, J. Meng, J. Wang, Sh. Zheng, X. Xu. “Deep learning for prediction of hepatocellular carcinoma recurrence after resection or liver transplantation: a discovery and validation study”, *Hepatol. Int.*, **16**:3 (2022), pp. 577–589. [doi](#)

- [24] A. A. Borisov, S. S. Semenov, K. M. Arzamasov. “Transfer Learning for automated search for defects on chest X-rays”, *Medicinskaya vizualizaciya*, **27**:1, pp. 158–169 (in Russian). [doi](#)
- [25] J. S. Whaley, B. D. Pressman, J. R. Wilson, L. Bravo, W. J. Sehnert, D. H. Foos. “Investigation of the variability in the assessment of digital chest X-ray image quality”, *J. Digit. Imaging*, **26**:2 (2013), pp. 217–226. [doi](#)
- [26] Society of Radiology (ESR) European. “What the radiologist should know about artificial intelligence — an ESR white paper”, *Insights Imaging*, **10**:1 (2019), id. 44. [doi](#)