

# Система определения патологий на рентгенограммах грудной клетки на основе сверточных нейронных сетей и обработки изображений при помощи нечетких множеств

Н. Е. Староверов<sup>1</sup>, А. Ю. Грязнов<sup>1</sup>, И. Г. Камышанская<sup>2</sup>,  
К. К. Гук<sup>1</sup>, Е. Д. Холопова<sup>1</sup>, И. А. Ларионов<sup>1</sup>

<sup>1</sup> Санкт-Петербургский государственный электротехнический университет  
«ЛЭТИ» им. В.И. Ульянова (Ленина)

<sup>2</sup> Санкт-Петербургский государственный университет  
nik0205st@mail.ru

**Аннотация.** В работе рассмотрено создание системы определения патологий на рентгенограммах грудной клетки на основе сверточных нейронных сетей и обработки изображений при помощи нечетких множеств. Тема работы является актуальной, поскольку на сегодняшний день методы, основанные на сверточных нейронных сетях, широко применяются для распознавания объектов на изображении. Архитектура системы строится на нескольких нейронных сетях. На первом этапе выполняется сегментация изображения для поиска областей интереса, затем классификации и детекция найденных патологий. Разработанная система позволяет определять пневмоторакс, очаговые затенения, пневмонию, ателектаз и гидроторакс. Кроме того, система предоставляет информацию о точной локализации патологии. В процессе выполнения работы были проведены испытания на реальных рентгеновских снимках, для всех классов была получена чувствительность и специфичность более 0.9.

**Ключевые слова:** рентгенография, сверточные нейронные сети, обработка изображений

## I. ВВЕДЕНИЕ

На современном этапе развития науки и техники широко используют сверточные нейронные сети для медицинских систем поддержки принятия решений. Важно отметить, что алгоритм автоматизированного поиска патологии на рентгенограмме не может заменить врача-рентгенолога и поставить за него диагностическое заключение, но должен привлечь его внимание на те снимки, где с высокой долей вероятности есть патология. Использование моделей на основе сверточных нейронных сетей в системах поддержки принятия решений позволит повысить выявляемость заболеваний при скрининговых исследованиях. Еще одним важным преимуществом таких систем поддержки принятия решений является оперативность, что позволяет маркировать снимки на которых с высокой вероятностью есть патология и предлагать врачу описать их в первую очередь. Применение для сегментации и обработки сегментированных изображений нечетких множеств позволяет точнее определять патологию на рентгеновском снимке.

## II. МАТЕРИАЛЫ И МЕТОДЫ

Для создания модели, распознающей отдельные заболевания органов грудной клетки по рентгеновским изображениям в прямой проекции, были собраны наборы данных для обучения и тестирования. Обезличенные рентгенограммы органов грудной клетки (ОГК) были получены из рентгеновских кабинетов больниц и поликлиник. Все снимки были размечены опытными врачами-рентгенологами.

В медицинских учреждениях было собрано 10765 снимков. Кроме того, использовались несколько открытых наборов данных, так что общее число снимков для обучения составило 42378, данные из открытых источников не использовались для валидации модели.

Для тренировки модели была применена концепция переноса обучения (transfer learning). При переносе обучения используется уже обученная на другом наборе данных нейронная сеть, которую затем дополнительно обучают на имеющихся данных. На сегодняшний день перенос обучения широко применяется для задач классификации изображений.

Сверточные нейронные сети, предварительно обученные на наборе данных ImageNet доступны во всех широко распространенных библиотеках глубокого обучения. В данной работе была выбрана библиотека PyTorch, поскольку использовалась сеть, обученная на наборе данных ImageNet [1]. Ввиду того, что изображения из него в большинстве своем достаточно сильно отличаются от рентгеновских снимков, потребовалось обучать не только последний слой (классификатор), но и последний и предпоследний сверточные слои. Наилучших результатов удалось достичь, используя для обучения различных слоев отличающиеся скорости. Так наименьшую скорость обучения имел сверточный слой, находящийся ближе всего ко входу сети, а наибольшую – линейный классификатор. Для всех сверточных слоев выполняется свертка с ядром размером 5x5 элементов, в сверточный слой включен слой с функцией активации (ReLU) и нормализация по батчу (Batch Normalization) [2, 3, 4]. Слои подвыборки уплотняют карту признаков, каждая группа пикселей 2x2 уплотняется до 1. В ходе исследования было замечено, что применение простого сжатия изображений приводит к значительным ошибкам

при классификации. При сжатии медицинских изображений формата 2000x2000 пикселей к формату 224x224 пропадает ценная диагностическая информация (такое сжатие требуется для корректной работы с предобученными сетями).

Для преодоления указанной проблемы к рентгеновским снимкам применялся алгоритм, повышающий резкость и контраст деталей изображения, описанный в [5, 6], затем изображение сжималось до размера 1024x1024. При помощи экспертов-рентгенологов было установлено, что в таком случае потери информации на снимках минимальны.

В качестве функции ошибки была использована бинарная кросс-энтропия (Binary cross-entropy loss), выражение для расчета функции ошибки:

$$BCE\_loss = \sum_{c=1}^C \sum_{n=1}^N -w_{n,c} (y_{n,c} \cdot \log(x_{n,c}) + (1 - y_{n,c}) \cdot \log(1 - x_{n,c})) \quad (1)$$

где  $C$  – количество классов,  $N$  – количество примеров,  $w_{n,c}$  – вес примера,  $y_{n,c}$  – целевое значение для примера,  $x_{n,c}$  – предсказанное моделью значение.

Тренировка классификации осуществлялась 92 эпохи, и была выполнена на графическом процессоре для сокращения времени обучения. В ходе обучения максимизировалась чувствительность, так как в задачах связанных с поиском патологий больший вес имеют пропущенные случаи патологий, а не ложные срабатывания.

Основная модель состояла из нескольких уровней, что в виде блок-схемы представлено на рис. 1. Для сегментации были использованы сети архитектуры U-net, для классификации сеть ResNeXt101. На первом этапе выполняется классификация норма/патология, затем поиск конкретного класса патологии, после определения наиболее вероятных классов патологий для каждого запускается сегментация патологии. Такой подход позволяет эффективно сегментировать, как затенения, так и просветления на рентгенограмме органов грудной клетки.

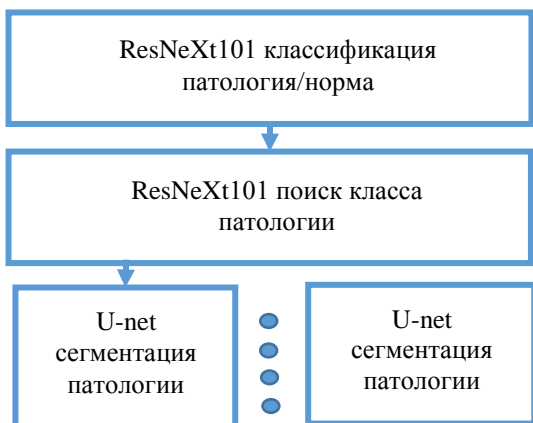


Рис. 1. Общая архитектура модели

Для обучения сетей архитектуры U-net были размечены по 200 снимков с каждой патологией, после применения U-net результаты были уточнены при помощи нечеткой логики. Так, уточнение было введено при помощи классификатора, которых по набору решающих правил определял наиболее вероятные границы объектов на сегментированных изображениях.

### III. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Результаты тестирования модели приведены в табл. 1. Для всех классов патологий удалось получить специфичность более 0.9.

ТАБЛИЦА I. РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ МОДЕЛИ

	Плевральный выпот	Пневмоторакс	Очаговое затенение
Чувствительность	90,58	90,43	92,25
Специфичность	90,12	90,91	90,75
Точность (общая валидность)	90,33	91,67	91,00
	Инфильтрация	Диссеминация	Полость
Чувствительность	90,49	93,90	91,50
Специфичность	90,53	92,89	94,51
Точность (общая валидность)	92,49	94,90	91,50
	Ателектаз	Кальцинат	Расширение средостения
Чувствительность	91,87	90,27	96,43
Специфичность	94,37	90,76	92,91
Точность (общая валидность)	92,00	90,00	90,67

Наилучшие результаты были получены для очаговых затенений и диссеминации.

Для всех моделей сегментации удалось получить dice score более 0.75, что позволяет считать, что сегментация выполняется качественно. На рис. 2 показан пример работы систем, выполнена классификация, определена инфильтрация в легких, показаны ее границы.




Рис. 2. Пример обработки исследования

Для практического использования разработанной системы было написано специализированное программное обеспечение. Программа работает по модели сервиса, принимая на вход исследование в формате DICOM. Результаты работы программы сохраняются в DicomSR формате в виде

структурированного отчета. Снимки с нанесенными на них контурами каждой патологии также сохраняются в формате DICOM. Интерфейс главного окна программы показан на рис. 3.



Рис. 3. Интерфейс главного окна программы

Загрузка и сохранение снимков могут производиться как из ПАКС, так и с жесткого диска персонального компьютера.

#### IV. ЗАКЛЮЧЕНИЕ

В результате исследования была разработана система поддержки принятия врачебных решений, которая позволяет определять и локализовывать патологии на рентгеновских снимках грудной клетки. При использовании разработанной системы без уточнения типа патологии (пневмоторакс, полость и др.), её чувствительность достигает 0,99. В случае дифференциации патологии для любого типа патологии чувствительность и специфичность остаются больше 0,9, что позволит использовать систему в медицинских учреждениях.

#### СПИСОК ЛИТЕРАТУРЫ

- [1] Paszke A. et al. Pytorch: An imperative style, high-performance deep learning library // Advances in neural information processing systems. 2019. Т. 32. С. 8026-8037.
- [2] He K. et al. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. С. 770-778.
- [3] Selvaraju R.R. et al. Grad-cam: Visual explanations from deep networks via gradient-based localization // Proceedings of the IEEE international conference on computer vision. 2017. С. 618-626.
- [4] Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // International conference on machine learning. PMLR, 2015. С. 448-456.
- [5] Staroverov N.E. et al. Development of digital processing method of microfocus X-ray Images // Journal of Physics. 2017.
- [6] Staroverov N.E., Gryaznov A.Y., Kholopova E.D. Digital x-ray image processing with using adaptive histogram equalization and adaptive background correction // Biomedical radio electronics. № 5 стр. 56-58.
- [7] Staroverov N.E. et al. Recognition of pathologies on chest x-rays using convolutional neural networks // AIP Conference Proceedings. AIP Publishing LLC, 2021. Т. 2356. №. 1. С. 020022.