

МИНИСТЕРСТВО ОБРАЗОВАНИЯ РЕСПУБЛИКИ БЕЛАРУСЬ

БЕЛОРУССКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ

**ФАКУЛЬТЕТ ПРИКЛАДНОЙ МАТЕМАТИКИ И
ИНФОРМАТИКИ**

Кафедра биомедицинской информатики

МАЛЫШЕВ

Валерий Дмитриевич

**РАЗРАБОТКА ОНЛАЙН СЕРВИСА ДЛЯ СЕГМЕНТАЦИИ
МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ**

Дипломная работа

Научный руководитель:
кандидат технических наук,
доцент Ковалев В.А.

Допущена к защите

«___» _____ 2019 г.

Зав. кафедрой биомедицинской информатики
кандидат физико-математических наук, доцент Ю. Л. Орлович

Минск, 2019

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	6
ГЛАВА 1 МАТЕРИАЛЫ	8
ГЛАВА 2 ОБЗОР ИССЛЕДОВАНИЙ	9
2.1 Алгоритм разделения графа	9
2.2 Итеративные пороги и ASM.....	10
2.2 Пороги, морфология и оператор обнаружения границ.....	10
2.3 ASM и AAM	10
2.4 ERF-ASM	10
2.5 MGRF и Shape Prior	11
2.6 Модель обратной связи	11
2.7 Distance Regularized Level Set Evolution (DRLSE).....	11
2.8 Content-Based Image Retrieval (CBIR).....	11
2.9 Удаление легочных структур перед сегментацией	11
2.10 Голосование между несколькими методами	12
ГЛАВА 3 НОРМАЛИЗАЦИЯ ИЗОБРАЖЕНИЙ	14
3.1 Описание проблемы и ожидаемый результат.....	14
3.2 Изображения с помехами или неподходящего качества.....	14
3.3 Алгоритм нормализации с помощью гистограммы.....	16
3.3 Эквиализация гистограммы	18
3.4 Изменение разрешения.....	21
ГЛАВА 4 СЕГМЕНТАЦИЯ ОБЛАСТИ ЛЕГКИХ НА РЕНТГЕНОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЯХ.....	22
4.2 Atlas-based сегментация	22
4.3 Сегментация с помощью нейронных сетей	23
ГЛАВА 5 ТЕСТИРОВАНИЕ КАЧЕСТВА СЕГМЕНТАЦИИ.....	25
5.1 Тестирование методов сегментации на точность сегментации	25
5.2 Тестирование методов сегментации с использованием задачи классификации	26

5.3 Результаты классификации	27
ГЛАВА 6 ИСПОЛЬЗОВАНИЕ СЕГМЕНТАЦИИ ДЛЯ ДИАГНОСТИКИ ЭМФИЗЕМЫ ЛЕГКИХ	29
6.1 Дескриптор, как набор различных глобальных признаков	30
6.3 Диагностика эмфиземы легких с помощью сверточной нейронной сети.....	34
6.4 Диагностика эмфиземы легких с помощью классификаторов.....	35
ГЛАВА 7 РАЗРАБОТКА ПО ДЛЯ СЕГМЕНТАЦИИ ОБЛАСТИ ЛЕГКИХ НА РЕНГЕНОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЯХ	38
ГЛАВА 8 РАЗРАБОТКА ОНЛАЙН СЕРВИСА	43
8.1 Схема использования приложения пользователем	43
8.2 Клиентская часть	44
8.3 Серверная часть	44
ЗАКЛЮЧЕНИЕ	46
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ	47
ПРИЛОЖЕНИЕ А	52

Реферат

Дипломная работа, 52 страницы, 36 рисунка, 5 таблиц, 12 формул, 59 источников.

Ключевые слова: БИОМЕДИЦИНСКИЕ ИЗОБРАЖЕНИЯ, РЕНТГЕНОГРАФИЯ, СЕГМЕНТАЦИЯ, КЛАССИФИКАЦИЯ, ДЕСКРИПТОР, ВЕБ-СЕРВИС, НЕЙРОННЫЕ СЕТИ, МАШИННОЕ ОБУЧЕНИЕ, ЭМФИЗЕМА.

Объект исследования – сегментация изображений.

Цель работы – разработка онлайн сервиса для сегментации рентгенографических изображений грудной клетки.

В ходе работы изучены основные методы сегментации области легких на рентгенографических изображениях и проведено их сравнение, протестированы различные методы нормализации и сегментации. Показана применимость методов сегментации для автоматической диагностики рентгенограмм. На основе полученных знаний разработано и реализовано программное обеспечение для сегментации области легких, а также проверена его эффективность. С использованием данного программного обеспечения был реализован веб-сервис для сегментации.

Данный веб-сервис предоставляет возможность проводить исследования в области автоматической диагностики рентгенограмм грудной клетки без траты времени и человеческих ресурсов на решение задачи сегментации.

Abstract

Diploma thesis, 52 pages, 36 figures, 5 tables, 12 formulas, 59 sources.

Keywords: BIOMEDICAL IMAGES, X-RAY, SEGMENTATION, CLASSIFICATION, WEB SERVICE, NEURAL NETWORKS, MACHINE LEARNING.

Object of research – image segmentation.

Objective – development of web-service for chest X-Ray segmentation.

During the study were investigated and compared basic methods for lungs area segmentation on chest X-Ray images. Different methods of image normalization and segmentation were tested. This study shows possibility of lungs segmentation application in computer-aided diagnostics of X-Ray images. Based on the obtained knowledge was developed and tested a software for lungs area segmentation. As a result of study, web-service for segmentation using that software was developed.

The web-service provides an opportunity for future use in studies of computer-aided diagnostics of chest X-Ray, which can save time and human resources on lung segmentation developing.

ВВЕДЕНИЕ

Рентгенография грудной клетки – это классическое исследование, чаще проводимое в процессе скрининга населения для диагностики патологических изменений в грудной клетке. С помощью этого метода могут быть диагностированы или выявлены подозрения на следующие часто диагностируемые заболевания:

- Пневмония,
- Туберкулез,
- Пневмоторакс,
- Гидроторакс,
- Интерстициальные заболевания легких,
- Сердечная недостаточность (отек легких),
- Грыжа пищеводного отверстия диафрагмы.

При некоторых заболеваниях органов грудной клетки рентгенография хороша в качестве скринингового метода, однако имеет недостаточную диагностическую ценность; в этих случаях проводятся дополнительные исследования, например компьютерная томография (КТ).

Основной задачей в обработке рентгенографических изображений грудной клетки является компьютерная диагностика рентгеновских снимков. В работе с изображениями широко применяется метод сегментации, в том числе при работе с рентгеновскими снимками грудной клетки.

Целью данной работы была разработка онлайн сервиса для сегментации рентгенографических изображений грудной клетки, что включает изучение существующих методов сегментации, их применение и настройка на имеющихся данных, а также оценка эффективности этих методов.

На сегодня почти отсутствует информация об эффективности сегментации в обработке рентгенографических изображений методами машинного обучения. С одной стороны, выделение области интереса с помощью сегментации фокусирует работу алгоритмов машинного обучения на ней. С другой, это ограничивает «видимость» для методов машинного обучения. Для этого в этой работе сегментация использовалась для классификации рентгенографических изображений по возрастным группам и классификации для поиска больных эмфиземой легких.

Объект исследования – сегментация изображений.

Предмет исследования – сегментация легких на рентгеновских снимках, зависимость эффективности классификации изображений от использованного

алгоритма сегментации или его отсутствия на различных типах входных данных.

Работа состоит из введения, восьми глав и заключения.

Введение раскрывает актуальность, цель исследования, обозначает теоретическую и практическую значимость работы.

В первой главе приводится описание использованных в этой работе данных.

Во второй главе рассматриваются существующие методы сегментации легких на рентгенографических изображениях, а также приводится их сравнение.

В третьей главе даются представления об использованных методах нормализации изображений.

В четвертой главе рассматриваются алгоритмы сегментации области легких с помощью алгоритма регистрации изображений и сверточных нейронных сетей.

Пятая глава посвящена сравнительному анализу представленных методов сегментации, а также эффективности их использования в задаче классификации.

В шестой главе рассматриваются методы и результаты диагностики эмфиземы легких на рентгенографических изображениях с использованием сегментации.

В седьмой и восьмой главах описана разработка программного обеспечения (ПО) и онлайн-сервиса для сегментации легких на рентгеновских снимках.

В заключении подводятся итоги исследования и разработки, формируются выводы по рассматриваемой теме.

ГЛАВА 1 МАТЕРИАЛЫ

В данном разделе описаны использованные данные и методы, которыми они были получены.

Набор данных JSRT (Japanese Society of Radiological Technology) – база рентгеновских снимков грудной клетки, которые содержат изображения с и без легочных узлов. Эта база была выложена в свободный доступ Обществом японских радиологических технологий. JSRT содержит 247 изображений грудной клетки разрешением 2048x2048 и имеют 12-и битную шкалу для интенсивностей пикселей. Из 247 изображений 154 содержат легочные узлы: 100 опасных случаев, 54 благоприятных и 93 типичных случая. Для улучшения набора JSRT была представлена база данных «Сегментация на Рентгенограммах грудной клетки» [1]. Этот набор рентгенографических изображений содержит сегментацию JSRT для легких, сердца и аорты. Также JSRT содержит данные о пациентах в текстовом виде, а именно: возраст, пол, область с патологией, если таковая имеется.

Montgomery – набор рентгенографических изображений из департамента здравоохранения и социальных служб округа Монтгомери, штат Мэрилэнд, США [2]. Этот набор содержит 800 изображений, собранных в рамках программы контроля за туберкулезом в округе Монтгомери. Рентгенограммы имеют разрешение 4020x4892 и 12-и битную глубину серого.

Также использовался большой приватный набор изображений, состоящий из более чем миллиона изображений, однако брались только части этого набора изображений. Размеры и свойства выборок из этого набора, использованных для конкретных целей, будут указаны в следующих главах.

ГЛАВА 2 ОБЗОР ИССЛЕДОВАНИЙ

Сегментация области легких из рентгеновских снимков грудной клетки имеет большое значение в области исследований автоматической диагностики заболеваний грудной клетки. Обозначение областей ребер, сердца и ключицы на изображении требуют различных методов сегментации, которые могут оказаться полезными для работы с рентгенографическими изображениями [3; 4; 5]. Согласно литературе, для сегментации используются различные методы: такие как активный контур [6; 7], алгоритм с наращиванием областей [8; 9], метод, основанный на вейвлетах [10; 11], а также методы, основанные на признаках [12] и гистограмме [13] и так далее. Более точная форма легких была получена с помощью комбинаций различных масок [14]. Также был разработан другой подход с использованием нечеткой кривой для определения границ легких в задаче диагностики эмфиземы.

В методах компьютерной диагностики (CAD), таких как идентификация туберкулеза, выделение областей легких на рентгеновских снимках грудной клетки [2; 14–18] или другие методы поиска аномалий грудной клетки [19; 20; 21] является критическим шагом. При обработке изображений обычно основной целью является извлечение важной информации таким образом, чтобы она не влияла на структуру изображения. Наиболее важным шагом, который требуется для достижения этой цели, является устранение шума или улучшение изображения [22; 23]. Как только работа над качеством изображения завершена, можно выполнять операции над этим изображением. Индикативные рамки, полученные с помощью сегментации, могут помочь рентгенологу в работе, а также использоваться в дальнейших операциях с изображениями. Сегментация области легких является одним из основных и необходимых шагов для выявления рака легких, туберкулеза и других заболеваний с помощью автоматических систем. А также имеется ряд других методов [24–30].

2.1 Алгоритм разделения графа

В этом методе сначала вычисляется маска для формы легких, с помощью поиска похожих уже отсегментированных изображений через похожесть распределения интенсивностей пикселей, а после усреднение масок выбранных изображений [26]. Для уточнения границ сегментации после создания усредненной маски используется алгоритм разделения графа. Тестирование этого метода на наборе данных JSRT показало 91% точности. Несмотря на высокую скорость такого подхода, такой подход просто создает статическую

модель формы. Поэтому в этой работе использовались методы позволяющие сделать модель более гибкой и общей.

2.2 Итеративные пороги и ASM

Этот метод представляет из себя структуру для итеративной сегментации с помощью порогов, которая использует набор сегментированных изображений со статистической информацией о форме левого и правого легких [31]. После сегментации к границе сегментированных легких еще применяется модель активной формы (Active Shape Model – ASM). Этот метод был использован и с другими признаками и подходами к их группировке [1,3].

2.2 Пороги, морфология и оператор обнаружения границ

Эта стратегия сегментации основана на генерации базовой маски легких с помощью порогов и итеративного применения морфологии для сглаживания и приближения к реальным границам легкого границы сегментации [32]. Для проведения тестирования использовались 1130 снимков, из которых 400 снимков были сделаны из шанхайского центра легочной медицины, а остальные 730 снимков были получены в других клиниках Китая. Точность достигла 88% результата, используя Dice score на указанном наборе данных. Также существует другой метод выделения области легких с использованием оператора Кэнни и морфологических операторов [33]. Эта стратегия проста, но было использовано только десять изображений из набора данных JSRT, на которых точность составила 0.809. Кроме того, не указаны критерии, по которым выбирались изображения из JSRT.

2.3 ASM и AAM

Эксперименты показали чувствительность 0,95% и специфичность 0,98% для сегментации набора данных JSRT с помощью видоизмененной ASM, с principal component analysis (PCA) [27]. Существует еще один эффективный алгоритм сегментации области легких, который зависит от статистической формы и моделей активного внешнего вида (Active Appearance Model – AAM) [34]. Данный алгоритм имеет точность 93.1% на общедоступном наборе данных, то есть JSRT. Однако этот подход требовал обучения и оптимизации.

2.4 ERF-ASM

«Global edge and area force (ERF) field-based ASM» (ERF-ASM) – измененная техника ASM [35]. Тестирование на наборе данных JSRT показало 95% точности в левом легком и 95% – в правом легком. Однако эта стратегия нуждается в настройке с точки зрения обучения и оптимизации.

2.5 MGRF и Shape Prior

Для томографии грудной клетки существует комбинированный метод для сегментации области легких [36]. В этом методе использовалась техника shape prior и трехмерная модель случайного поля Маркова – Гиббса (MGRF). В экспериментах с компьютерной томографией был достигнута 0,969 Dice score.

2.6 Модель обратной связи

Это гибридная модель сегментации на основе пороговых значений и морфологии, которая связана с моделью обратной связи [37]. Алгоритм сегментации дает индекс сходства 96,52% и 98,21% по Intersection over Union (IoU) и Dice score соответственно для левого легкого и 97,42% и 98,58% по IoU и Dice score для правого легкого. Эти результаты были получены на 96 изображениях Thorax-НСТ из больницы Куала-Лумпур.

2.7 Distance Regularized Level Set Evolution (DRLSE)

Комбинация Distance Regularized Level Set Evolution (DRLSE) с принципами глубокого обучения на наборе данных JSRT показала точность 94,8–98,5% (диапазон получился из-за зависимости метода от способа инициализации) [38]. Ограничением этой стратегии является то, что она требует подготовки. Кроме того, она содержит этап инициализации, который выполняется вручную.

2.8 Content-Based Image Retrieval (CBIR)

Полностью автоматический подход, основанный на контентно-ориентированной системе поиска изображений (Content-Based Image Retrieval – CBIR), критерии подобия Бхаттачарьи и алгоритме разделения графа, протестированный на трех наборах данных, показал точность 95% для набора данных JSRT, 94% для набора данных Монтгомери и 91% для набора данных из Индии [2]. Несмотря на высокие показатели точности, недостатком этого алгоритма является то, что он является эвристическим и требует больших вычислительных затрат и подготовки для проведения сегментации рентгенографии грудной клетки.

2.9 Удаление легочных структур перед сегментацией

Также была предложена полуавтоматическая структура методов для сегментации области легких на компьютерной томографии [39]. Эта структура представляет комбинацию низкоуровневой обработки, которая включает в себя автоматическое итеративное определение порога, удаление дыхательной

системы, удаление легочного дерева. После проводится процесс ручного выбора точек, с которых начнется сегментация. Этот метод не сегментировал должным образом изображения, которые имеют патологии, рассеянные по все области легких.

2.10 Голосование между несколькими методами

Среди трех гибридных методов для сегментации, лучший выбирался, используя голосование по принципу максимальной точности из различных моделей [1].

В таблице 1 представлено краткое изложение обсуждаемых методов в табличной форме.

Таблица 1 – Сравнение методов сегментации легких на рентгенографических изображениях

Метод	Результаты (Intersection over Union если не сказано другое)	Ограничения	Набор данных
Порог и ASM [40]	92.5% – 94%	Малый размер тестовой выборки	Приватный
Итеративные пороги и ASM [31]	22 признака: 92% 28 признаков: 94%	Требует оптимизации	JSRT
Модель обратной связи [37]	Левое легкое: 96.52% Правое легкое: 97.42%	Недостаточно изображений	Приватный
Статистическая форма и AAM [34]	93%	Требует оптимизации	JSRT
Удаление структур и ASM [39]	83.7% – 95.6%	Полуавтоматический Мало изображений	Компьютерная томография
Алгоритм разделения графа [26]	91%	Статичная модель	JSRT
DRLSE [38]	94.8 – 98.5%	Требует оптимизации Неавтоматическая инициализация	JSRT

Метод	Результаты (Intersection over Union если не сказано другое)	Ограничения	Набор данных
		параметра 'k'	
MGRF и Shape prior [36]	0.969 Dice score	Требует оптимизации мало информации	КТ легких
ASM и PCA [27]	Чувствительность: 0.95 Специфичность: 0.98	Имеет недостаток ASM	JSRT
ERF-ASM [35]	95%	Требует оптимизации	JSRT Приватный набор
CBIR [2]	JSRT: 95% Montgomery: 94%	Вычислительно сложная модель	JSRT Montgomery
Комбинирование масок легких [14]	AUC 83.12% (для поиска туберкулеза)	Статичная модель	JSRT

ГЛАВА 3 НОРМАЛИЗАЦИЯ ИЗОБРАЖЕНИЙ

3.1 Описание проблемы и ожидаемый результат

Необходимость нормализации обусловлена тем, что изображения имеют различные контрастность, яркость и разрешение. Это может быть вызвано как биологическими особенностями, так и особенностями оборудования, так как использованные изображения рентгенографии грудной клетки получались на различном оборудовании. Нормализация уменьшает влияние данных различий на результаты вычислений, а также позволяет восстановить засвеченные изображения.

Нормализация базируется на построении гистограмм яркости и «обрезке» определенных диапазонов, зависящих от максимального значения интенсивности пикселей на изображении, для получения более равномерного распределения интенсивности на изображении. Также в ходе этого процесса всем пикселям, не относящиеся к человеческому телу, на изображении следует присвоить нулевое значение.

Ввиду вычислительной сложности алгоритмов сегментации сегментация оригинальных изображений займет крайне много времени. Радиографические изображения в базе данных для алгоритма сегментации также имеют разрешение 256x256 и расчет классификаторов зависит от разрешения. Поэтому будет эффективно изменить разрешение изображений выборки.

В результате были получены изображения со следующими свойствами

- Значения яркости пикселей, находящихся на изображении тела, находятся в диапазоне [0,255] (1 байт),
- Все изображения имеют одинаковое разрешение 256x256.

3.2 Изображения с помехами или неподходящего качества

3.2.1 Определение проблемы

На некоторых изображениях можно заметить артефакты, вызванные помехами при получении изображения. Помехи могли быть вызваны металлическими предметами на теле или внутри. Например, наручные часы или кардиостимулятор. Так как такие предметы довольно малы по сравнению с остальной частью изображения, они не приводят к некорректной нормализации и имеют яркость ненамного превосходящую максимальную в пределах тела. В связи с тем, что для целей данной работы необходимо только отсутствие помех в области легких, то предметы, накладывающийся на изображение легких (например, кардиостимулятор), в дальнейшем вызовут некорректное

определение области легких на изображении. Однако, такие изображения довольно редки, и чаще всего вызывают ошибку при сегментации, что приводит к удалению данного изображения из выборки, таким образом ввиду малого количества таких изображений они искажают последующие результаты крайне незначительно.

Также помехи могут быть вызваны оборудованием, и чаще всего имеют вид белой линии на изображении. Такие линии имеют максимальную яркость на изображении, сильно превосходящую реальную максимальную яркость, которая будет достигаться на каком-то пикселе на части изображения внутри тела. Это приводит к сильному увеличению границ гистограммы, а следовательно, к некорректно определенным границам и неверно проведенной нормализации.

3.2.2 Решение

Как было показано ранее, наличие металлических предметов на рентгенографическом изображении не влияет на конечный результат. Таким образом, следует использовать метод, который позволит убрать яркие пиксели (На рисунке 1 можно заметить, что основная часть изображения имеет серый цвет, это обусловлено тем, что белый цвет используется как цвет для пикселя с максимальной яркостью, однако, после обработки, на рисунке 2 видно, что основная часть изображения имеет максимальную яркость).



Рисунок 1 – Изображение до обработки

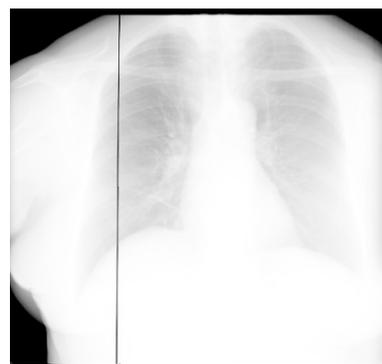


Рисунок 2 – Изображение после обработки

На рисунках 3, 4 изображены гистограммы интенсивностей пикселей изображений на рисунках 1, 2 соответственно. На рисунке 3 можно видеть, что имеется очень небольшое количество пикселей с яркостью от 25000 до 30000, они являются изображением помехи. Алгоритму требуется найти все пиксели не относящиеся к изображению тела (на рисунках 3,4 можно видеть, что основная часть пикселей имеет яркость от 18000 до 25000 – это пиксели относящиеся к изображению тела) и имеющих яркость выше максимальной интенсивности на теле. Для этого алгоритм выбирает 2.5% пикселей, с наибольшим значением яркости, от общего количества пикселей на изображении и присваивает им максимальное значение, которое имеется в оставшихся 97.5%. Данный результат достигается с помощью построения гистограмм яркости. На рисунке 4 можно заметить, что после работы алгоритма максимальная значение яркости, достигаемое на изображении, уменьшилось.

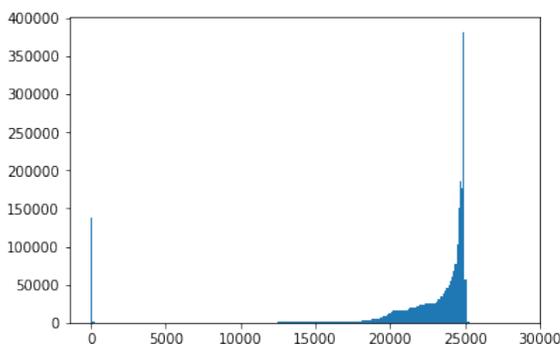


Рисунок 3 – Гистограмма до обработки

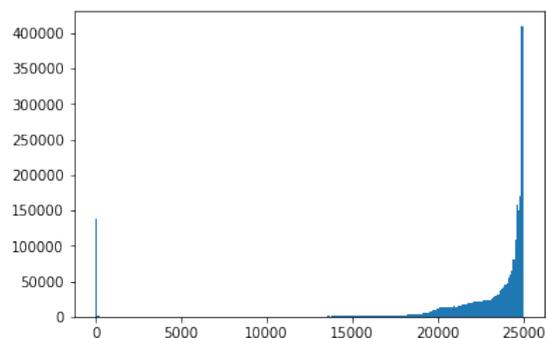


Рисунок 4 – Гистограмма после обработки

3.3 Алгоритм нормализации с помощью гистограммы

3.3.1 Работа с фоном

Так как при работе с изображениями рекомендуется отделить фон от изображения тела, то наилучшим способом сделать это является присвоить значение 0 интенсивности всем пикселям фона. Так как при проведении рентгенографии грудной клетки излучение рассеивается, то на изображении границы будут размыты и фон не будет иметь нулевое значение.

Строя гистограммы яркости для различных изображений, можно заметить, что на изображениях имеется две основных группы пикселей. Одну, наибольшую и имеющую большие значения, можно поставить в соответствие изображению тела, вторая, меньшая, является фоном, это хорошо видно на рисунке 5. Следовательно, надо отделить все пиксели из второй группы и присвоить им значение 0. Так же можно заметить, что эти части можно

разделить, разделив гистограмму посередине. Поэтому всем пикселям, имеющим значение яркости меньше, чем половина от максимального значения яркости, присваивается значение 0.

В некоторых случаях это может привести к тому, что части изображения тела будет присвоен 0. Однако этой частью будет являться граница между телом и фоном и внутренняя часть легких (так как легкие занимают значительный объем внутри грудной клетки и заполнены воздухом, оказывающим крайне малое сопротивление рентгеновским лучам, то они будут иметь низкое значение яркости на изображении).

3.3.2 «Обрезка» гистограммы

Как было показано в разделе 1.1 яркость пикселей изображения, полученного в результате, должна попадать в диапазон [0,255]. Однако на изображении могут быть артефакты. Поэтому надо провести операцию аналогичную описанной в пункте 3.2.2. Также на изображении могут остаться ненулевые пиксели. Поэтому такую операцию следует провести, с другой «стороны». То есть выбираются 2.5% пикселей, имеющих минимальное ненулевое значение и им, присваивается 0.

Далее строится гистограмма яркости, имеющая 256 столбцов. И каждому пикселю присваивается номер столбца, в который он попал. Таким образом получается изображение, удовлетворяющее указанным критериям. Обработанная гистограмма из рисунка 5 представлена на рисунке 6.

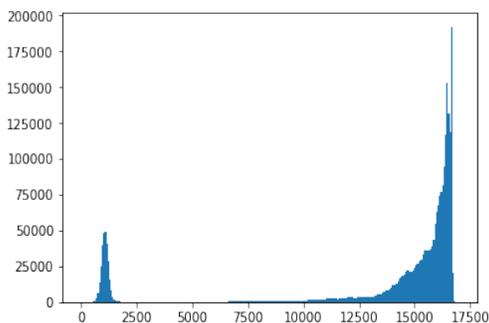


Рисунок 5 – Гистограмма до обработки

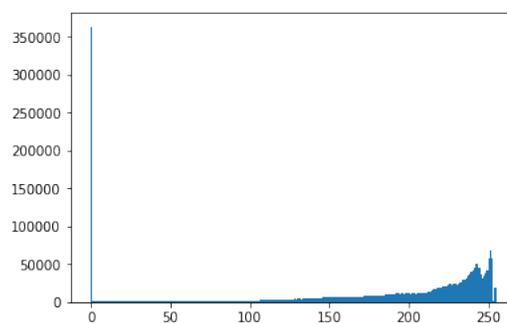


Рисунок 6 – Гистограмма после обработки

3.3.3 Преимущества и недостатки

Преимущества:

- Избавляется от зависимости изображения от аппарата, на котором оно было получено;

- Довольно быстрый;
- Не требует большого объема памяти.

Недостатки:

- Не отражает индивидуальных особенностей человека. Так как контрастность изображения, яркость и так далее могут зависеть от плотности и количества тканей.

3.3 Эквиализация гистограммы

Из-за алгоритма работы с фоном, на некоторых изображениях затемняется область легких, что приводит к потере информации, содержащейся в этой области рентгенографического изображения, пример такого изображения представлен на рисунке 7. Поэтому был выбран немного иной способ растяжения гистограммы и увеличения контраста, а именно – эквиализация гистограммы яркостей изображения.

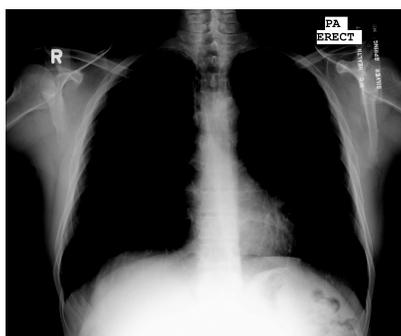


Рисунок 7 – Плохой пример нормализации с помощью обрезки гистограммы

Эквиализация гистограммы – это метод нормализации для улучшения контраста на изображении. Он достигает этого через эффективное растяжение наиболее часто встречаемых интенсивностей на больший диапазон значений интенсивности. В итоге, если рассматривать изображение, как случайное распределение, то после эквиализации гистограммы функция распределения приближается к функции равномерного распределения.

Так как пиксели на изображении имеют целочисленное значение интенсивности, то подходит следующее преобразование для получения эквиализированной гистограммы:

- Пусть n_i – количество пикселей изображения, имеющих интенсивность равную i . Вероятность встречи пикселя со значением интенсивности x равным i определяется формулой (1):

$$p_x(i) = p(x = i) = \frac{n_i}{n}, 0 \leq i < 256 \quad (1)$$

где n – количество всех пикселей в изображении, $p_x(i)$ по факту является значением столбца гистограммы изображения для значения интенсивности i , нормализованное к диапазону $[0,1]$;

- Тогда функцию распределения для изображения можно задать формулой (2):

$$cdf(i) = \sum_{j=0}^i p_x(j) \quad (2)$$

которая также является кумулятивной нормализованной гистограммой изображения.

- Применив преобразование $T(k)$ по формуле (3) к каждому пикселю с интенсивностью k , получаем изображение Y :

$$T(k) = \left\lfloor 256 * \sum_{n=0}^k p_n \right\rfloor \quad (3)$$

где 256 – количество возможных интенсивностей пикселей.

- Рассматривая распределения интенсивностей изображения как непрерывные случайные величины, и предположив, что они дифференцируемы получаем формулу (4):

$$\int_0^y p_y(z) dz = \int_0^{T^{-1}(y)} p_x(w) dw \quad (4)$$

где y – интенсивность пикселя изображения Y , $T^{-1}(y)$ – функция обратная $T(x)$. Продифференцировав по y , получаем равенство (5):

$$\frac{d}{dy} \int_0^y p_y(z) dz = p_y(y) = p_x(T^{-1}(y)) \frac{d}{dy} (T^{-1}(y)) \quad (5)$$

- Используя равенство (6):

$$\frac{d}{dy} T(T^{-1}(y)) = \frac{d}{dy} y = 1 \quad (6)$$

и применив (5) получаем равенство (7):

$$\begin{aligned} \frac{dT}{dy} \Big|_{x=T^{-1}(y)} \frac{d}{dy} (T^{-1}(y)) &= 256 * p_x(T^{-1}(y)) \frac{d}{dy} (T^{-1}(y)) = \\ &= 256 * p_y(y) = 1 \end{aligned} \quad (7)$$

- Разделив равенство (7) на 256, получаем равенство (8):

$$p_y(y) = \frac{1}{256} \quad (8)$$

что показывает равномерность распределения интенсивностей нормализованного изображения. Так как изображение имеет все-таки дискретное распределение, равномерность не будет строго соблюдаться.

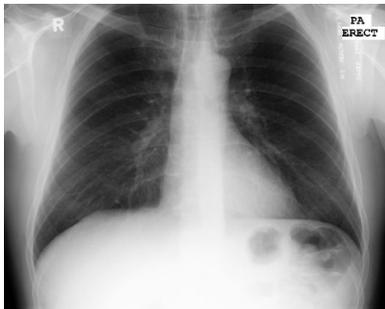


Рисунок 8 – Изображение до эквализации



Рисунок 9 – Изображение с эквализированной гистограммой

На рисунках 8 и 9 изображены рентгенографические изображения до и после эквализации гистограммы яркостей, а на 10 и 11 их гистограммы. На рисунке 12 можно видеть кумулятивную гистограмму яркостей, на которой видно, что эквализированная гистограмма яркостей приближена к функции равномерного распределения [41].

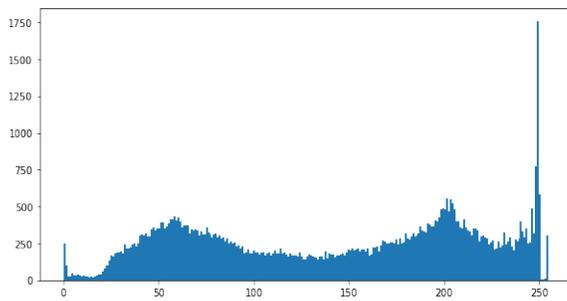


Рисунок 10 – Гистограмма исходного изображения

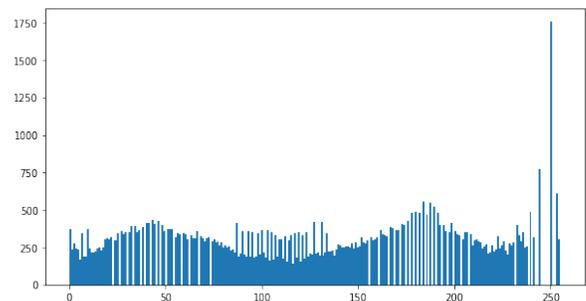
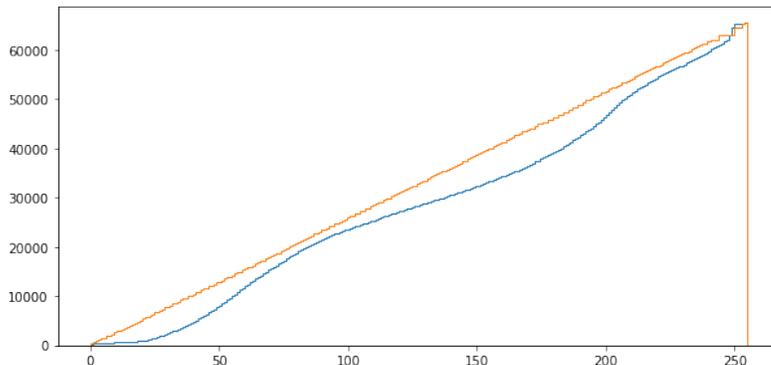


Рисунок 11 – Эквилированная гистограмма



**Рисунок 12 – Кумулятивная гистограмма интенсивностей изображения
синяя линия – до эквализации, оранжевая – после**

3.4 Изменение разрешения

Для изменения разрешения изображения (в данном случае, уменьшения) я воспользовался библиотекой OpenCV и методом, который устанавливает значения цвета пикселей как среднее значение пикселей, которые находились на его месте в оригинальном изображении. При использовании данного метода в результате получаются наиболее сглаженные изображения. Также этот метод наиболее производительный при уменьшении разрешения изображения более чем в 10 раз [42]. Разрешение уменьшалось с 1635x1536 до 256x256, то есть в 38 раз.

ГЛАВА 4 СЕГМЕНТАЦИЯ ОБЛАСТИ ЛЕГКИХ НА РЕНТГЕНОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЯХ

В этой главе рассматривается несколько методов сегментации, а именно atlas-based сегментация рентгенографических изображений с помощью нежесткой трансформации и сегментации сверточными нейронными сетями.

4.2 Atlas-based сегментация

Для алгоритма atlas-based сегментации требуются изображения с предварительно выделенными областями легких. В атласе (базе изображений) находилось 300 рентгенографических изображений и соответствующие им сегментированные маски легких, файл с перечнем изображений атласа и с посчитанными классификаторами для них.

В процессе работы было добавлено 1179 новых изображений, используя сегментированные изображения с помощью atlas-based сегментации, которые были подправлены в неверно отсегментированных местах. Ввиду того, что на добавленных изображениях отсутствовало выделение ключевых точек, а их выделение требовало значительных временных затрат, данная особенность алгоритма не использовалась.

Алгоритм atlas-based segmentation [2] был реализован с использованием утилиты elastix [43]. Суть данного метода состоит в следующем: для сегментируемого изображения вычислялся вектор признаков – массив чисел, представляющий собой суммы значений пикселей по каждой строке, столбцу и разделенные на количество пикселей на изображении [1]. Далее выбирается пять изображений из атласа с наименьшим корреляционным расстоянием между собственными векторами и вектором признаков сегментируемого изображения. Далее находятся нежесткие (повороты, сдвиг, масштабирование) преобразования, трансформирующие изображения из атласа в исходное. Затем строится искомая «маска» изображения (на рисунке 13 представлена «маска легких», представленная на рисунке 14, наложенная на рентгенографическое изображение), как среднее между «масками» легких изображений из атласа, к которым применили найденные соответствующие преобразования.



Рисунок 13 – Сегментированная область легких на рентгенографии



Рисунок 14 – Сегментированная "маска" легких

Ввиду способа, которым вычисляются классификаторы и необходимости изменения разрешения «маски», если разрешение сегментируемого изображения не совпадает с разрешением изображений из базы данных, что вызывает искажения, сегментируемая выборка требует приведения к разрешению 256x256 (разрешение изображений в атласе).

Этот алгоритм довольно точный, но при его использовании на изображениях из другого набора данных могут возникнуть значительные погрешности в сегментации. Также такой алгоритм сегментации является довольно медленным – требуется около одной секунды на обработку одного изображения.

4.3 Сегментация с помощью нейронных сетей

Также для сегментации использовались сверточные нейронные сети с двумя архитектурами: AlexNet [44] и U-Net [45].

AlexNet является довольно простой нейронной сетью (рисунок 15). Так как AlexNet создана для классификации изображений, то она требовала адаптации, а именно замены полно-связных слоев на сверточные и обратно-сверточные слои с таким же количеством выходных каналов, как и в оригинальных полно-связных слоях [46]. Это позволило сети вместо того, чтобы классифицировать изображения, определять принадлежность пикселей к легким.

U-Net – это архитектура полной сверточной нейронной сети, которая была создана для сегментации биомедицинских изображений (рисунок 16). Сеть содержит 23 сверточных слоя и разделена на две части: «сжимающий путь» и «расширяющий путь». «Сжимающий путь» является типичной сверточной нейронной сетью. «Расширяющий путь» содержит слои обратные сверточным,

и на каждом этапе признаки, полученные после расширения, объединяются с соответствующей картой признаков из «сжимающего пути».

Примеры сегментации с помощью указанных архитектур нейронных сетей представлена на рисунках 17 и 18. Обе нейронных сети использовали для тренировки базу сегментированных изображений описанную в 4.1. Таким образом все три алгоритма сегментации использовали одни и те же данные.

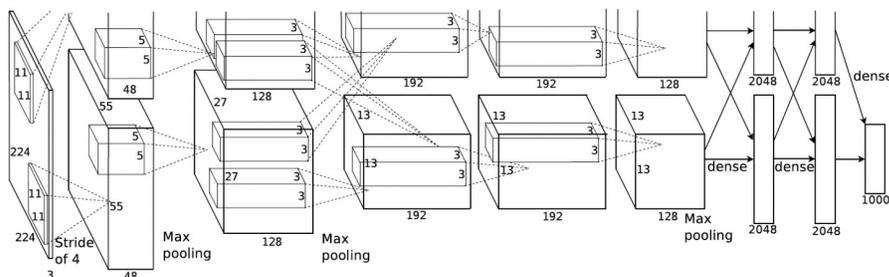


Рисунок 15 – Архитектура AlexNet

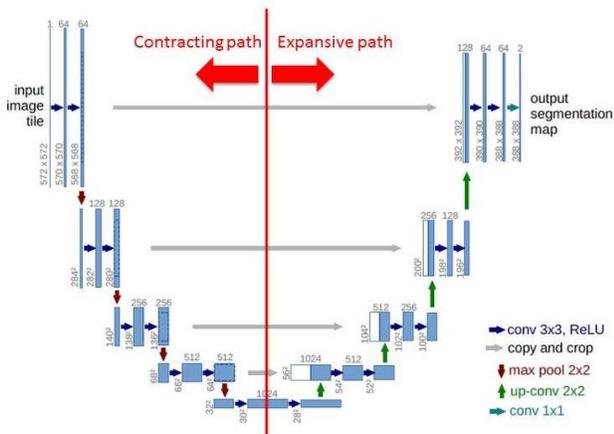


Рисунок 16 – Архитектура U-Net



Рисунок 17 – Сегментация с помощью AlexNet



Рисунок 18 – Сегментация с помощью U-Net

ГЛАВА 5 ТЕСТИРОВАНИЕ КАЧЕСТВА СЕГМЕНТАЦИИ

5.1 Тестирование методов сегментации на точность сегментации

Так как конечной целью работы была разработка онлайн сервиса для сегментации, который, вообще говоря, должен сегментировать рентгенографические изображения вне зависимости от того, на каком оборудовании они получены, то вместо разделения набора данных на набор для тренировки и для тестирования использовался другой набор данных для тестирования. А именно, описанные методы сегментации были протестированы на наборе рентгенографических изображений Montgomery, состоящего из 800 рентгеновских снимков, с помощью Intersection over Union (IoU) и Dice score. Результаты представлены в таблице 2. На рисунке 19 показаны примеры хорошей и плохой сегментации изображений из этого набора рентгенограмм.

Таблица 2 – Intersection over Union и Dice Score при тестировании сегментации

Метод	IoU	Dice score
Atlas-based	0.87	0.92
AlexNet	0.85	0.92
U-Net	0.84	0.91

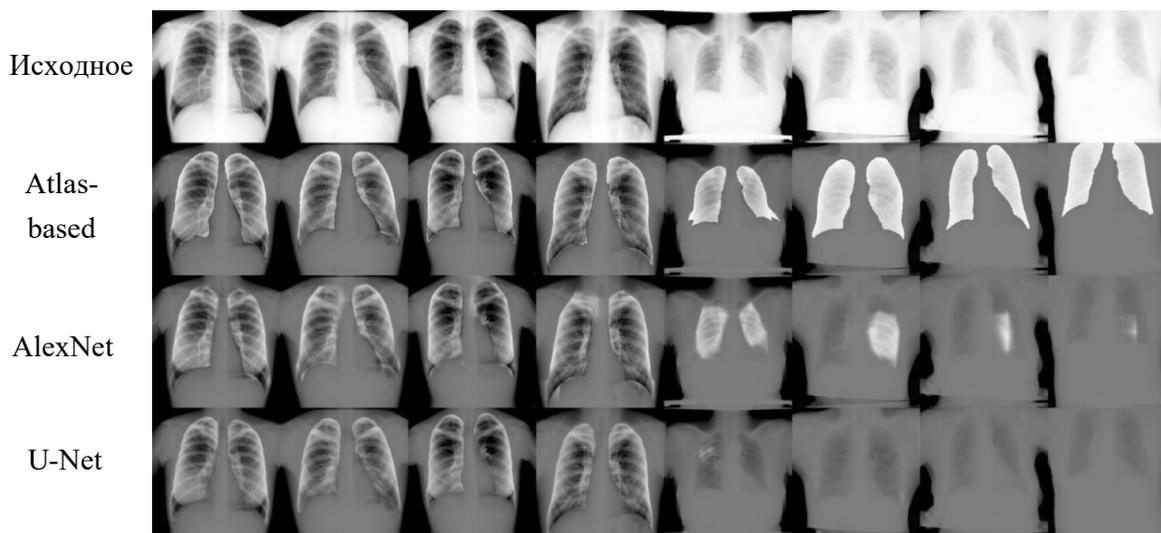


Рисунок 19 – Результаты сегментации. 4 хорошо (слева) и 4 плохо (справа) отсегментированных изображения

5.2 Тестирование методов сегментации с использованием задачи классификации

В качестве задачи для проверки эффективности сегментации была выбрана задача классификации рентгенографических изображений по трем возрастным группам пациентов: от 20 до 30, от 40 до 50, от 60 до 70 лет. Для данной задачи использовались изображения из приватного набора: 1190 изображений для каждого возраста и пола, что дает 26180 рентгенографических изображений для каждого класса.

Эта задача была выбрана, так как существует зависимость объема и формы легких от возраста. Также очевидна зависимость между площадью легких на изображении и реальным объемом легких [47]. Таким образом, задача классификации изображений по возрастным группам чувствительна к точности нахождения площади легких. Алгоритмы сегментации находят форму легких на изображении и, следовательно, их эффективность напрямую влияет на точность классификации.

Были использованы три метода различной сложности, самый простой из них – логистическая регрессия по одному значению, извлеченному из изображения. Другими методами классификации были глубокая нейронная сеть на целых изображениях или масках легких и RandomForest (случайный лес) на признаках изображений.

Во-первых, логистическая регрессия работала с одним значением для каждого изображения или маски легких, которая представляла собой сумму интенсивностей пикселей, вычисляемую по формуле (9) (приложение А):

$$\sum_{i=1, j=1}^{N, M} I(i, j) \quad (9)$$

где $I(i, j)$ - интенсивность пикселя в i -й строке и j -м столбце в изображении разрешением $N \times M$. Для масок изображения эта сумма показывает площадь легких относительно изображения. Как известно, объем легких уменьшается с возрастом [47], поэтому площадь легких на рентгеновском изображении тоже уменьшается. Для оригинальных рентгеновских снимков грудной клетки уменьшение площади легких увеличивает эту сумму.

В качестве глубокой нейронной сети была выбрана архитектура Inception-v3 [48], которая обучалась и тестировалась на масках легких без бинаризации. Кроме того, сеть была применена к другим изображениям, которые

представляли собой шум, в который была вставлена часть изображения с легкими, вырезанными из рентгеновского изображения грудной клетки с помощью маски легких (рисунок 20) (эти изображения упоминаются в таблице 2 как легкие с шумом). Этот подход показал, как использование внутренней структуры легких влияет на оценку классификации. Кроме того, сеть была протестирована на рентгенограммах грудной клетки без сегментации.

RandomForest использовал предварительно вычисленные векторы признаков, которые были извлечены из тех же данных, которые использовались в нейронной сети. Признаками первого типа были гистограммы Local Binary Patterns (LBP) [49] с радиусом 1 и 4. Признаки SURF (Speeded Up Robust

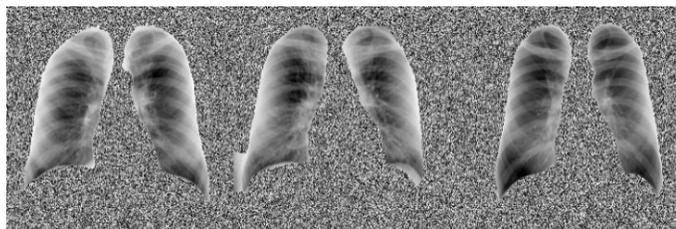


Рисунок 20 – Изображения с шумом

Features) [50], которые являются дескрипторами градиента в областях ключевых точек, были вторым типом. Они рассчитывались в 4 ключевых точках, которые покрывают большую часть изображения с областью легких. Более подробное описание признаков приведено в главе 6.

5.3 Результаты классификации

В качестве основного показателя для оценки эффективности классификации использовалась площадь под ROC-кривой (AUC). AUC используется для бинарной классификации, но у этой задачи было три возрастных класса. Таким образом, для расчета глобального AUC использовалась формула (10):

$$AUC_{total} = \frac{2}{|C|(|C| - 1)} \sum_{\{c_i, c_j\} \in C} AUC(c_i, c_j) \quad (10)$$

где C — это набор классов. Для этой проблемы общее значение AUC является средним для класса AUC, поскольку изображения были классифицированы по 3 возрастным группам. Кроме того, в таблице 3 представлены оценки AUC комбинаций различных методов сегментации и классификации. Полужирным выделены лучшие показатели в столбцах таблицы.

Таблица 3 – AUC различных комбинаций методов сегментации и

классификации

Сегментация	Логистическая регрессия	Inception v3		RandomForest	
Исходное	0.648	0.935		0.813	
	Сумма интенсивностей	Маска легких	Легкие с шумом	Маска легких	Легкие с шумом
Atlas-based	0.630	0.891	0.907	0.811	0.743
AlexNet	0.578	0.880	0.912	0.813	0.730
U-Net	0.604	0.901	0.885	0.781	0.714

Легко заметить, что использование исходных рентгенографических изображений превосходит модели сегментации, что отличает результаты от ожидаемых. Объяснение для логистической регрессии может заключаться в том, что средняя масса тела населения растет с возрастом [51], что в комбинации с уменьшением площади легких на рентгеновском изображении грудной клетки дает больший эффект на сумму интенсивности пикселей рентгенограммы грудной клетки (рис. 2), чем просто уменьшение площади легких. Скорее всего, это приводит к лучшей классификации с помощью логистической регрессии для исходных изображений. Для других типов классификации причиной может быть сокращение области интереса для алгоритмов машинного обучения. Другими словами, сегментация сокращает возможные признаки, которые могут быть обнаружены классификаторами.

Это показывает, что проблема классификации рентгенограмм грудной клетки – не лучший способ оценить качество сегментации. Например, выявление или классификация заболеваний легких могут прояснить больше, поскольку в этих задачах не ожидается признаков за пределами области легких. В качестве такой задачи была взята задача выявления эмфиземы легких, описанная в следующей главе.

ГЛАВА 6 ИСПОЛЬЗОВАНИЕ СЕГМЕНТАЦИИ ДЛЯ ДИАГНОСТИКИ ЭМФИЗЕМЫ ЛЕГКИХ

Эмфизема легких – это хроническое неспецифическое заболевание легких, форма хронической обструктивной болезни легких (ХОБЛ), в основе которого лежит необратимое расширение воздухоносных пространств и повышенное вздутие (воздушность) легочной ткани. Диагностика патологии проводится с учетом данных аускультации, рентгенографии и КТ легких, спирографии, анализа газового состава крови.

Эмфизема легких является широко распространенным заболеванием, частота встречаемости которого среди населения превышает 4%. Социальная значимость заболевания определяется высоким процентом нетрудоспособности и инвалидизации, возрастающей смертностью в индустриальных странах. По прогнозам Всемирной Организации Здравоохранения хроническая обструктивная болезнь легких станет третьей наиболее распространенной причиной смерти [52].

Исследования показали точность в 83.12% на задаче выявления туберкулеза и других легочных заболеваний с использованием данных о форме легких, полученных с помощью сегментации и признаков рентгенографических изображений [14]. Однако в данной работе использовалась только информация, получаемая из отсегментированной области легких, как и признаки, посчитанные только в этой области, чтобы оценить, как сегментация влияет на выявление эмфиземы.

Для данной задачи использовалось 30095 рентгенографических изображений людей, больных эмфиземой. К каждому изображению была подобрана рентгенография здорового человека того же возраста и пола. То есть 60190 изображений с сбалансированными классами здоровых и больных эмфиземой.

Используя atlas-based сегментацию на нормализованных данных, были получены маски легких. Так как эмфизема легких не влияет на размер и форму легких, можно приводить сегментированные легкие к одному разрешению, пока оно позволяет различить структурные изменения, свойственные этому заболеванию. Поэтому для вычисления дескрипторов использовались изображения легких в разрешении 128x128, полученные путем наложения маски на нормализованное изображение (такое изображение, полученное из рентгенограммы на рисунке 21, представлено на рисунке 22).



Рисунок 21 – Исходное изображение

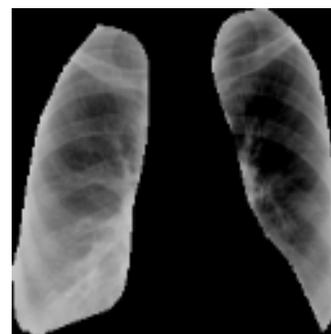


Рисунок 22 – Изображение легких

Данные были разделены на группы для тренировки, валидации и тестовую в соотношении 4:1:1. Также снимки одного человека (сделанные в разные года), принадлежащие одному классу, находятся в одной группе данных для того, чтобы предотвратить возможность того, что классификаторы будут определять конкретных людей, а не саму болезнь.

6.1 Дескриптор, как набор различных глобальных признаков

6.1.1 Матрицы совместной встречаемости

Матрицы совместной встречаемости являются текстурными признаками, которые основываются на комбинациях пикселей относительно друг друга на изображении. Строки и столбцы представляют интенсивность (или диапазон интенсивностей), а элемент матрицы $P(i, j | dx, dy)$ есть частота встречаемости комбинации пикселей (i, j) , разделенных расстоянием (dx, dy) [53]. В данной задаче использовались матрицы по четырем направлениям (горизонтальное, вертикальное и диагональные), так есть $P(1, 0)$, $P(1, 1)$, $P(0, 1)$, $P(-1,1)$, что соответствует углам 0° , 45° , 90° , 135° . Для уменьшения количества используемой памяти и итогового количества признаков использовались диапазоны размером 16 значений интенсивностей в каждом. То есть получилось 4 матрицы $16 * 16$. Всего 1024 признака. Также не учитывались комбинации интенсивностей, если хотя бы один пиксел имел значение 0, таким образом, матрицы совместной встречаемости вычислялись только на непосредственно изображении легких, не затрагивая фон.

6.1.2 Локальные бинарные шаблоны

Локальные бинарные шаблоны (Local Binary Patterns, далее LBP) являются локальным контрастным признаком. Для каждого пикселя изображения вычисляется его новое значения, основываясь на значениях его соседей. Значение рассматриваемого пикселя устанавливается как порог, соседним

пикселям ставится в соответствие значение 1, если интенсивность больше интенсивности рассматриваемого, в противном случае – 0. Далее полученные значения умножаются на «вес» соседнего пикселя и складываются [49]. Результат применения LBP показан на рисунке 23. Данный признак имеет смысл, так как LBP является локальным текстурным признаком, а эмфизема может быть локализована в различных частях легкого и иметь различные размеры. Рассматривать еще одно изображение является крайне затратным по времени обработки, поэтому использовалась гистограмма «изображения», полученного применением LBP (рисунок 24).



Рисунок 23 – LBP применённое к рисунку 22

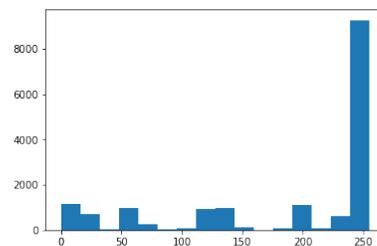


Рисунок 24 – Гистограмма LBP

6.1.3 Дискретное вейвлет-преобразование (DWT)

Вейвлетами называются функции, которые удовлетворяют некоторым математическим условиям и используются в представлении данных или других функций. Основной идеей вейвлетов является представление любого сигнала в виде суперпозиции базисных функций. Дискретное вейвлет-преобразование для изображений может быть определено по формуле (11):

$$\omega(a_1, a_2, b_1, b_2) = \frac{1}{\sqrt{a_1 a_2}} \Psi\left(\frac{X - b_1}{a_1}, \frac{Y - b_2}{a_2}\right) \quad (11)$$

где a_1 и a_2 являются коэффициентами расширения, b_1 и b_2 коэффициентами сдвига, Ψ — трансформирующая функция [54]. Дискретное вейвлет-преобразование раскладывает изображение на несколько наборов коэффициентов используя ортогональный набор функций: коэффициенты аппроксимации и детализирующие коэффициенты (в горизонтальном, вертикальном и диагональном направлениях).

Данный метод можно применять несколько раз, используя на каждом следующем шаге аппроксимирующие коэффициенты из предыдущего. Также после каждого применения разрешение уменьшается в два раза по обоим направлениям.

Использование данного метода позволяет получить информацию о небольших изменениях относительно всего изображения. В качестве признаков использовались детализирующие коэффициенты по всем трем направлениям в результате четырех последовательных применений DWT. Результат представлен на рисунке 25.

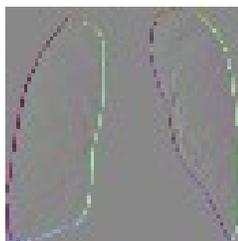


Рисунок 25 – Детализирующие коэффициенты после первого применения DWT к рисунку 22 (R — по горизонтали, G — по вертикали, B — по диагонали)

6.1.4 Метод главных компонент (PCA)

Метод главных компонент является одним из основных способов уменьшить размерность данных, потеряв наименьшее количество информации. С помощью методов указанных в 6.1.1-6.1.4 было получено 1064 признака для каждого изображения. Так как использовать все признаки неэффективно с

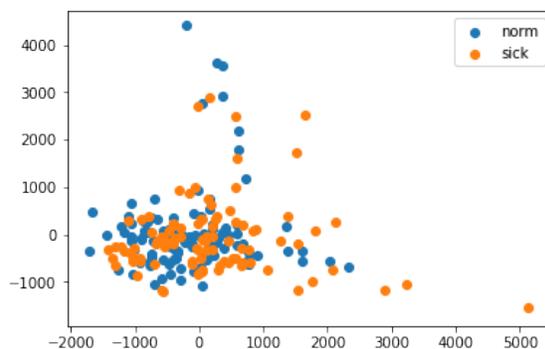


Рисунок 26 – Визуализация данных

(100 здоровых и 100 больных, объем сохраненной информации — 76.5%) точки зрения количества вычислений и памяти, я использовал метод главных компонент, чтобы свести эти признаки к 64-ем компонентам (признакам). Объем сохраненной информации составил 99.6%. Также PCA был использован для визуализации данных, приведя 64 компоненты к 2 компонентам для визуализации (рисунок 26).

6.1.5 SURF Дескриптор

SURF дескриптор вычисляется на некоторых ключевых точках. Поиск точек происходит в пространстве $\{x, y, \sigma\} \in \mathbb{R}^3$, где σ представляет масштаб пространства, в котором существует фильтр для поиска ключевых точек [55]. Сам дескриптор определен как гистограмма направлений градиентов в локальной окрестности ключевой точки (рисунок 27). В итоге для каждой ключевой точки получается вектор длины 64.

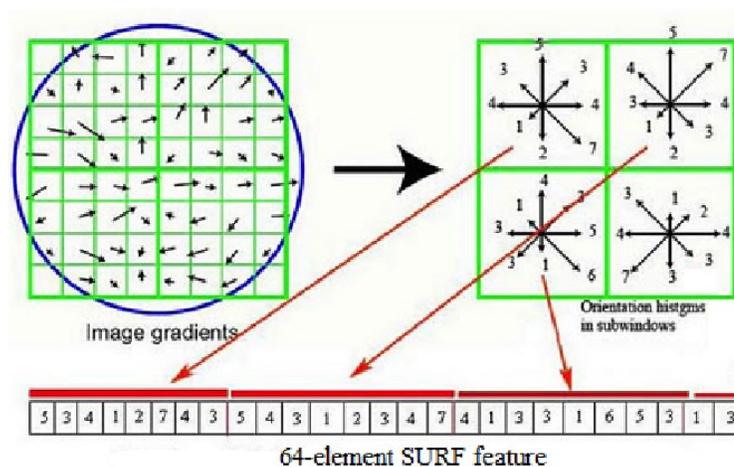


Рисунок 27 – Принцип вычисления SURF дескриптора [56]

Проблема использования ключевых точек, найденных алгоритмом SURF, заключается в том, что количество этих точек может варьироваться в зависимости от изображения, что приводит к непостоянной длине дескриптора (количество точек * 64). Также даже равное количество ключевых точек не гарантирует того, что они будут находиться на одинаковых позициях относительно структуры изображения. Поэтому вместо SURF обнаружения ключевых точек использовались фиксированные точки (рисунки 28, 29).

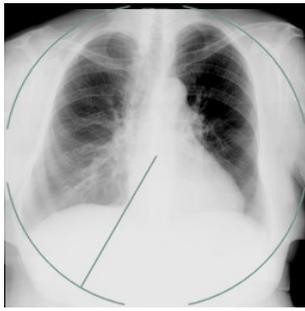


Рисунок 28 – Одна ключевая точка

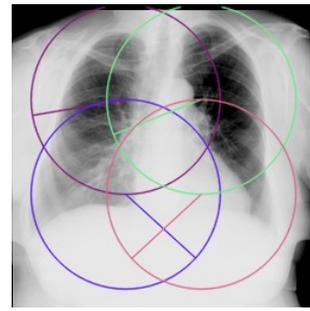


Рисунок 29 – 4 ключевые точки, локализованные в области легких

6.3 Диагностика эмфиземы легких с помощью сверточной нейронной сети

Первым способом для классификации изображения для выявления рентгенограмм людей больных эмфиземой была сверточная нейронная сеть со следующей структурой:

- а)** Свертка $3 * 3$, 64 канала;
- б)** max-пулинг $2 * 2$;
- в)** Свертка $3 * 3$, 64 канала;
- г)** Свертка $3 * 3$, 128 каналов;
- д)** max-пулинг $2 * 2$;
- е)** Свертка $3 * 3$, 128 каналов;
- ж)** Свертка $3 * 3$, 256 каналов;
- з)** max-пулинг $2 * 2$;
- и)** Свертка $3 * 3$, 256 каналов;
- к)** Свертка $3 * 3$, 256 каналов со сдвигом на 2;
- л)** max-пулинг $2 * 2$;
- м)** Свертка $3 * 3$, 256 каналов;
- н)** Свертка $3 * 3$, 256 каналов со сдвигом на 2;
- о)** max-пулинг $2 * 2$;
- п)** Свертка $3 * 3$, 256 каналов;
- р)** max-пулинг $2 * 2$;
- с)** На данный момент из исходного изображение получился вектор длиной 256;
- т)** Полносвязный слой $256 * 64$;
- у)** Полносвязный слой $64 * 2$;
- ф)** Softmax.

В качестве входных данных используются изображения легких, полученные из исходных нормализованных рентгенограмм (Рис. 11). Размер блока изображений для тренировки использовался 16. Обучение происходило в течение 32 эпох.

Исходное изображение (128,128,1), функцией активации для свертки и полносвязных слоев была выбрана ReLU. Также после каждой свертки использовалась нормализация блока изображений (batch normalization). Перекрестная энтропия использовалась как функция ошибки: $H(p, q) = -\sum p(x) \log q(x)$, где p — экспериментальные данные, q — предсказанные нейросетью. В качестве оптимизатора был выбран оптимизатор Адама.

Общая точность на тестовой группе данных составила 71%. Класс точно был определен для 68% изображений нормы и 74% людей больных эмфиземой. На группе изображений для валидации точность составила 68%.

6.4 Диагностика эмфиземы легких с помощью классификаторов

Support Vector Machines, RandomForest и k -ближайших соседей — алгоритмы машинного обучения с учителем. Эти алгоритмы использовались чтобы классифицировать рентгенографические изображения на норму и изображения людей, больных эмфиземой, используя дескрипторы, описанные в главе 3.

6.4.1 Support Vector Machines (SVM)

SVM решает задачу классификации, как задачу нахождения оптимальной разделяющей гиперплоскости. Так есть, гиперплоскости, которая максимизирует расстояние между плоскостью и ближайшими к ней точками в пространстве признаков из обоих классов [57].

6.4.2 RandomForest

RandomForest представляет из себя набор деревьев решений, каждое из которых «голосует» за некоторый класс, а после эти результаты суммируются. Каждое дерево решений строится следующим образом: из набора данных для обучения выбирается случайная подвыборка с повторениями, далее для построения узла дерева выбирается некоторое количество признаков, на основе которых происходит разбиение, и из этих выбирается наилучший [58].

6.4.3 k-ближайших соседей (kNN)

K-NN является довольно простым методом классификации, но несмотря на это он может быть довольно эффективным. Для каждой единицы данных t этот метод находит k (в данной задаче $k = 5$) соседей и назначает t класс, наиболее распространенный среди его k соседей [59].

6.4.4 Результаты

Как можно видеть из графика на рисунке 30, наилучший результат получается при использовании RandomForest на SURF дескрипторе основанном на 4 точках (рисунок 30). Средняя точность для этого метода составила 80.1% (рисунок 31). Что является наилучшим результатом, учитывая также сверточную нейронную сеть.

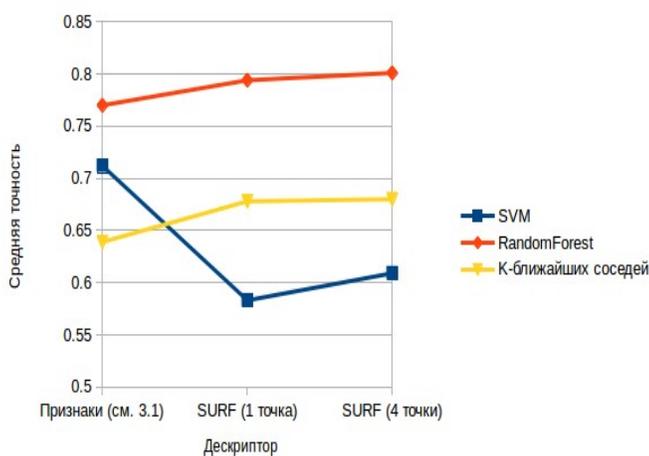


Рисунок 30 – Точность методов

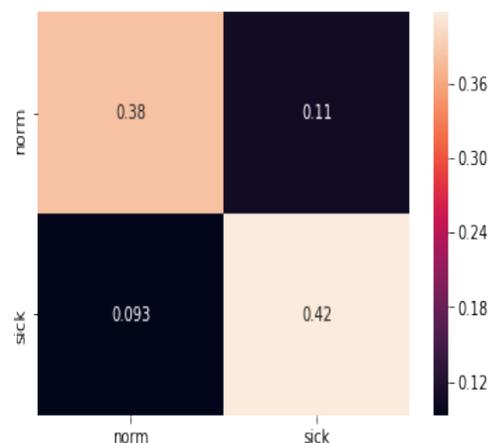


Рисунок 31 – Матрица ошибок для RandomForest на SURF (4 точки)

В этой главе была рассмотрена классификация рентгенографических снимков людей на два класса: больных эмфиземой и здоровых. Классификация проводилась с использованием нормализации и сегментации изображений, описанных выше. Используя алгоритмы машинного обучения для классификации изображений, были получены данные об их эффективности в диагностике эмфиземы.

Есть несколько способов улучшения данного результата. Например, нахождение ключевых точек, привязанных к структурным элементам легких, что позволит получить более значимые признаки изображений. Или использование разработанных признаков в сверточной нейронной сети, как входные данные в дополнение к полноценным изображениям.

Однако стоит отметить, что диагностика болезней легких, в частности, эмфиземы по рентгенографическому изображению, возможно только на поздней стадии, то есть использование рентгена вкупе с некоторыми другими данными (такими как предыдущая история болезни и некоторые факты о человеке, как, например, является ли он курильщиком).

Проведение такого эксперимента с диагностикой эмфиземы позволило показать, что использование сегментированных изображений легких может быть достаточно для получения адекватного результата.

ГЛАВА 7 РАЗРАБОТКА ПО ДЛЯ СЕГМЕНТАЦИИ ОБЛАСТИ ЛЕГКИХ НА РЕНГЕНОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЯХ

Основной идеей для разработки ПО послужила идея объединения рассмотренных выше методов для увеличения точности сегментации, а также добавления входного и выходного контроля, предобработки и постобработки изображений, чтобы предотвратить возможные ошибки сегментации. Это ПО должно работать за приемлемое время и с точностью, превышающей точность сегментации отдельными методами.

Входной контроль обеспечивает проверку каналов изображения на равенство, чтобы удостовериться, что на вход подается черно-белое изображение, а не цветное.

В модуле предобработки изображений приводились к одному формату, то есть изображения с разрешением 256×256 и максимальным значением интенсивности пикселя – 255, что описано в главе 1. В качестве нормализации проводилась эквализация гистограммы яркости изображения.

Полученные изображения сегментировались описанными в главе 4 методами по отдельности. Каждый метод сегментации работал в отдельных потоках и связывался с основной частью программы с помощью двух блокирующих очередей: одна для приема изображений, вторая для отправки маски отсегментированных легких. Для идентификации изображений использовалось имя файла, которое передавалось между различными потоками вместе с изображением. Это необходимо, так как сегментация изображения, поступившего раньше, может быть завершена позже, чем сегментация изображения, поступившего после первого.



Рисунок 32 – Объединенные маски легких до бинаризации

Каждый метод менял формат изображения (добавлял еще одно измерение к массиву или рассматривал черно-белое изображения как многоканальное), если это требовалось архитектурой метода, и проводил сегментацию. По возможности сегментация нейронными сетями проводилась блоками по 4 изображениями, чтобы ускорить процесс сегментации. После каждый блок сегментации отправлял полученную маску легких для их объединения, выходного контроля и постобработки в основном модуле.

Маски отсегментированных областей легких объединялись по принципу простого невзвешенного голосования по каждому пикселю (рисунок 32). В случае если несколько методов сегментации возвращает ошибку, то также проходит голосование на определение результата сегментации как ошибочного. Такой подход позволяет в будущем добавлять другие методы сегментации без сильного изменения существующей архитектуры. В процессе объединения проверялось, чтобы полученные маски легких были достаточно похожими, это проверялось с помощью попарной меры различия между результатами сегментации от различных методов:

$$\frac{|A \cap B|}{|A \cup B|} \quad (12)$$

где **A** и **B** – маски легких после бинаризации. Если величина различия, посчитанная по формуле (12) больше 0.4 то она добавлялась к сумме. Превышение этой суммы, нормированной на количество полученных масок легких (равное количеству используемых методов сегментации) значения 0.6 используется как сигнал о некорректной сегментации. Такой метод был выбран потому, что если подать на вход черно-белое не рентгенографическое изображение, то результат сегментации у разных методов с разными архитектурами может сильно отличаться. Это позволило находить черно-белые не рентгеновские изображения среди входных данных.

После объединения масок от различных методов, в модуле постобработки проверялось, есть ли отсегментированный участок на маске, то есть сумма интенсивностей должна быть ненулевой. Далее проводилась бинаризация маски с порогом 127 и убирались небольшие (<1% пикселей от общего количества пикселей изображения) светлые или темные отдельные участки. Для того, чтобы избавиться от возможных неверно сегментированных областей на объединенной маске, считалось количество отдельных регионов на маске. Их должно было получиться только два, по одному на каждое легкое. Если их больше двух и большинство маленькие, то их можно удалить как погрешность (рисунок 33), если же нет, то сегментация проведена неверно, о чем сообщается. Последним шагом проверяется достоверность сегментации следующим образом:

- Проверка площади отсегментированных областей легких на маске – эта площадь не должна быть меньше, чем 13% от размера изображения;
- Проверка сбалансированности правого и левого легкого на изображении – размеры белых областей с правой и левой стороны маски легких должны быть ненулевыми и отличаться не более чем в 5 раз.

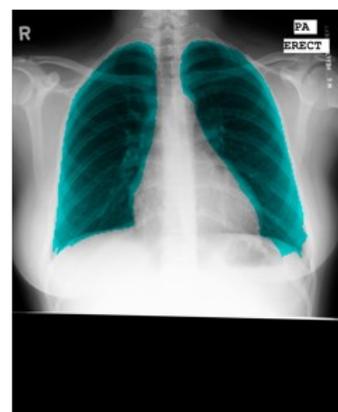


Рисунок 33 – Работа с контурами на маске

На выходе получается маска отсегментированных легких, если она есть (отсутствует если сегментация была проведена некорректно), и изображение с наложенной на него маской (рисунок 34).



Рисунок 34 – Результат работы ПО

Отдельные части программы работают асинхронно с использованием очередей в качестве связи между ними. В отдельных асинхронных блоках работают следующие блоки программы: загрузка, входной контроль, предобработка, каждый метод сегментации в отдельном потоке, соединение результатов сегментации в одно изображение, выходной контроль и постобработка.

Для оценки разработанного программного обеспечения для сегментации легких на рентгенографических снимках грудной клетки использовались несколько показателей. Первый — это точность сегментации, оцененная с помощью Intersection over Union и Dice score, эти показатели приведены в таблице 4 (для наглядности продублированы данные из таблицы 2). Вторым показателем определяет, как хорошо полученное ПО отсеивает не рентгеновские изображения. Для оценки этого показателя был взят набор изображений Caltech101, и из каждого 101 класса этого набора было выбрано случайным образом одно изображение для сегментации. Из набора рентгеновских изображений Montgomery было выбрано 52 рентгенографических изображений грудной клетки, в сумме 153 изображения. Результаты данного теста представлены в таблице 5.

Таблица 4 – Точность сегментации на наборе данных Montgomery

Метод	IoU	Dice
Atlas-based	0.87	0.92
AlexNet	0.85	0.92
U-Net	0.84	0.91
Разработанное ПО	0.91	0.96

Таблица 5 – Количество сегментированных изображений при тестировании постпроцессинга

	До сегментации	После объединения масок	После прохождения выходного контроля
Не X-Ray	101	2 (рисунок 35)	1
X-Ray	52	52	52

Можно видеть, что объединение нескольких методов сегментации улучшило общую точность сегментации.

Так как ошибка сегментации при сегментации рентгеновского изображения может вызвать худшие последствия, чем сегментация изображения, не являющегося рентгеновским снимком грудной клетки (что вообще маловероятно), пороги были выбраны так, чтобы рентгеновские снимки отбрасывались максимально редко.

Время работы ПО составляет 2-3с на одно изображение, однако этот промежуток может увеличиваться или уменьшаться в зависимости от используемой вычислительной машины.

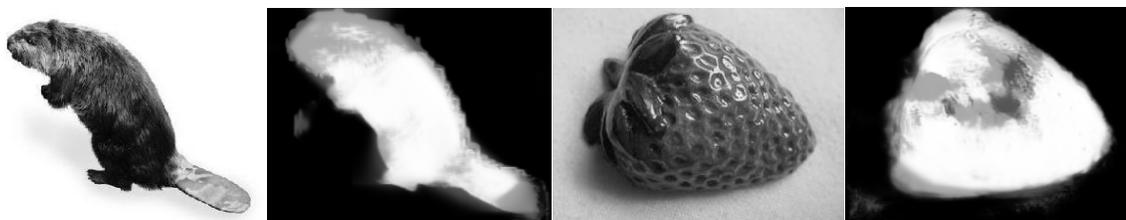


Рисунок 35 – Отсегментированные не рентгеновские изображения

ГЛАВА 8 РАЗРАБОТКА ОНЛАЙН СЕРВИСА

Для разработки онлайн сервиса требуется подготовить серверную часть, клиентскую часть, а также связать серверную часть с ПО, описанным в предыдущей главе. Для web-сервиса был выбран язык программирования JavaScript. В реализации серверной части использовался фреймворк Express – гибкий фреймворк Node.js для создания веб-приложений. Для клиентской части использовался React – библиотека JavaScript позволяющая создавать компоненты на клиентской части, которые объединяют вид, логику и состояние. Также вместе с React использовался JSX, который облегчает разработку компонент с React путем сокращения кода, требуемого для создания компонент в JavaScript коде. Кроме JavaScript использовались и другие стандартные технологии, такие как HTML5, CSS, JSON.

К приложению предъявлялись следующие основные функциональные требования:

- Загрузка рентгенографических изображений пользователем;
- Сегментация и отображение отсегментированных рентгенограмм;
- Предоставление пользователю возможности скачивать отсегментированные изображения по отдельности;
- Предоставление пользователю возможности скачать все отсегментированные изображение с масками легких

8.1 Схема использования приложения пользователем

Используя кнопку с символом «+» пользователь загружает до 5 изображений. Далее он нажимает кнопку «Upload», после чего загруженные изображения отправляются на сервер, где помещаются в рабочую директорию ПО для сегментации. Отсегментированные изображения помещаются в ту же директорию, откуда их забирает сервер и отправляет обратно на компьютер клиента. Все это время клиент видит индикатор, который сообщает, что изображения находятся в обработке. После получения изображений они отображаются в браузере пользователя. Нажатием на отсегментированное изображение он может скачать его. Сразу после получения всех отсегментированных изображений на стороне пользователя формируется архив, который он может скачать с помощью кнопки «Download result», архив содержит изображения с выделенными легкими, а также маску легких, а также в архиве сохранены названия файлов, отосланных пользователем. Пример работы с сервисом представлен на рисунке 34.

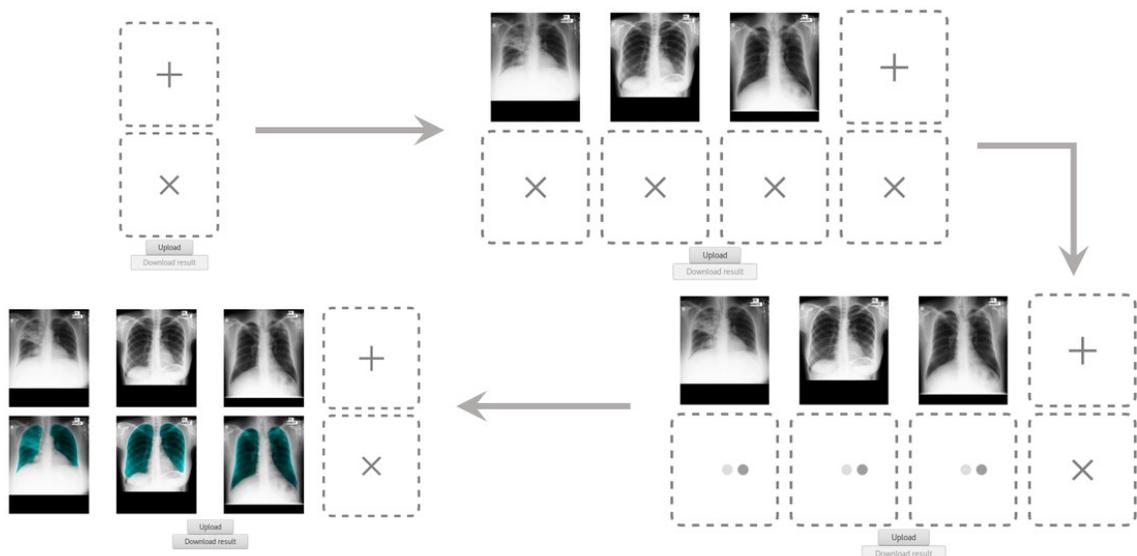


Рисунок 36 – Интерфейс онлайн сервиса

8.2 Клиентская часть

В клиентской части объявлены одна вспомогательная функция, которая переводит полученные изображения от сервера в формат, доступный для отображения с помощью React, две компоненты с «+» и «x» для уменьшения количества кода, функция Ajax, которая добавляет основной компонент приложения на страницы, и две компоненты с логикой сервиса.

Первая компонента ImageHolder создается при загрузке изображения. Этот компонент занимается отображением этого изображения и сегментированного или анимации, означающей, что сегментация в процессе. В этом компоненте осуществляется работа с сообщениями от сервиса Pusher, который будет описан чуть далее.

Вторая, основная компонента приложения, – ImageUploader. Этот компонент создается при загрузке страницы и через него осуществляется загрузка изображений, создание компонент ImageHolder. В этом компоненте осуществляется отправка POST запросов с формой с изображениями. Также этот компонент отвечает за формирование архива из отсегментированных изображений.

8.3 Серверная часть

В серверной части используется ряд библиотек. А именно:

- express – основная библиотека для запуска сервера и создания функций, отвечающих на запросы;

- `multer` – библиотека для загрузки нескольких файлов на сервер, смены названий файлов на другие, чтобы не было конфликтов, а также для проверки типов файлов на то, что это изображения;
- `path`, `fs` – библиотеки для работы с файловой системой сервера, в основном для проверки выходной директории ПО для сегментации на наличие там нужного сегментированного изображения;
- `body-parser` – библиотека для получения информации из форм, посылаемых с POST запросами;
- `helmet` – библиотека, контролирующая заголовки запросов для больше безопасности, также эта библиотека используется для установки заголовка `Content-Security-Policy`, устанавливающего список ресурсов, к которым может быть получен доступ;
- `python-shell` – библиотека, с помощью которой осуществляется запуск ПО, описанного в предыдущей главе, а также обмен сообщениями с ним;
- `pusher` – библиотека для доступа к сервису Pusher, который позволяет посылать сообщения от сервера пользовательской части.

После загрузки и настройки библиотек объявляется вспомогательная функция `prepareMask`, которая загружает изображения из выходной директории ПО, удаляет их и компонует их в один объект JSON для отправки пользователю.

С помощью библиотеки `express` объявлены функции для ответов на GET запросы, большинство из которых тривиальны и отправляют запрошенный файл, то есть скрипты для клиентской части, `css` и `html` файлы. Кроме этих запросов есть еще ответ на POST запрос для загрузки изображений, который использует библиотеку `multer` и следит, чтобы количество изображений, находящихся в обработке, не переполнилось. После загрузки изображения в рабочую директорию серверная часть посылает ПО имя файла и ПО начинает процесс сегментации этого изображения. После окончания сегментации ПО посылает сообщения с именем файла серверной части сервиса, который, в свою очередь отправляет клиентской части сообщения о готовности сегментации с помощью сервиса `pusher`. Получив сообщение, клиентская часть отправляет GET запрос для получения сегментированного изображения.

ЗАКЛЮЧЕНИЕ

В этой работе были рассмотрены методы обработки рентгенографических изображений, а именно нормализация и сегментация. Было приведено два подхода к нормализации, а также их плюсы и недостатки, проведен сравнительный анализ существующих методов сегментации, а также несколько из них: atlas-based сегментация и сверточные нейронные сети были применены в данной работе. Далее путем тестирования этих методов были получены точность сегментации и точность определения возрастного класса пациента на рентгенографическом изображении с использованием различных методов сегментации и классификации.

Диагностика эмфиземы позволила показать, какую точность можно получить, используя только текстуру и форму легких.

Полученные результаты и методы использовались для разработки ПО для сегментации области легких на рентгенографических снимках. Полученное ПО показало точность, сравнимую с приведенной в обзоре в главе 2. С помощью веб-разработки удалось связать данное ПО и веб-приложение. Таким образом, в случае решения других задач, связанных с автоматическими системами диагностики для рентгеновских изображений, можно избежать необходимости разрабатывать сегментацию области легких. В дальнейшем имеется возможность для расширения данного сервиса путем добавления сегментации других органов, которые могут быть обнаружены на рентгеновском снимке.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Segmentation of anatomical structures in chest radiographs using supervised methods: a comparative study on a public database / Van Ginneken B., Stegmann M.B., Loog M. // *Medical Image Analysis*. – 2006. Vol. 12, № 1. – P. 19–40.
2. Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration / Candemir S., Jaeger S., Palaniappan K. et. al.// *IEEE Transactions on Medical Imaging*. – 2014. Vol. 33. № 2. – P. 577–590.
3. Computer-aided diagnosis in chest radiography: a survey / Van Ginneken B., Romeny B.T.H., Viergever M.A. // *IEEE Transactions on Medical Imaging*. – 2001. Vol. 20, № 12. – P. 1228–1241.
4. Segmentation of anatomical structures in chest radiographs using supervised methods: a comparative study on a public database / Van Ginneken B., Stegmann M.B., Loog M. // *Medical Image Analysis*. – 2006. Vol. 10, №1. – P. 19–40.
5. Overview of technical elements of liver segmentation / Khan N., Ahmed I., Kiran M. et. al.// *International Journal of Computer Science and Applications*. – 2016. Vol. 7, № 12. – P. 271–278.
6. Abdel-massieh N.H. Fully automatic technique for liver segmentation from abdominal CT scan with knowledge-based constraints. – INTECH Open Access Publisher, 2012.
7. Computer-aided measurement of liver volumes in CT by means of geodesic active contour segmentation coupled with level-set algorithms / Suzuki K., Kohlbrenner R., Epstein M.L. et. al.// *Medical Physics*. – 2010. Vol. 37, № 5. – P. 2159–2166.
8. Automatic segmentation of liver and tumor for cad of liver / Kumar S., Moni R., Rajeesh J. // *Journal of Advances in Information Technology* – 2011. Vol. 2, № 1. – P. 63–70.
9. Automatic computer aided segmentation for liver and hepatic lesions using hybrid segmentations techniques / Anter A.M., Azar A.T., Hassanien A.E. et. al.// *Proc. Federated conference on computer science and information systems (FedCSIS)* – IEEE, 2013. – P. 193–198.
10. Melanocytic and nevus lesion detection from diseased dermoscopic images using fuzzy and wavelet techniques / Jamil U., Khalid S., Akram M.U. et. al.// *Soft Computing*. – 2018. Vol. 22, №5. – P. 1577–1593.
11. Content based image retrieval by using color descriptor and discrete wavelet transform // Ashraf R., Ahmed M., Jabbar S. et. al.// *Journal of Medical Systems*. – 2018. Vol. 42, №3. – P. 44.

- 12.MDCBIR-MF: multimedia data for content-based image retrieval by using multiple features / Ashraf R., Ahmed M., Ahmad U. et. al.// Multimedia tools and applications, 2018. – P. 1–27.
- 13.Intelligent image classification-based on spatial weighted histograms of concentric circles / Zafar B., Ashraf R., Ali N. et. al.// Computer Science and Information Systems. – 2018. Vol. 15, №3 – P. 615–633.
- 14.Detecting tuberculosis in radiographs using combined lung masks / Jaeger S., Karargyris A., Antani S. et. al.// Proc. Annual international conference of the IEEE Engineering in Medicine and Biology Society. – IEEE, 2012. – P. 4978–4981.
- 15Automatic detection of tuberculosis in chest radiographs using a combination of textural, focal, and shape abnormality analysis / Hogeweg L., Sánchez C.I., Maduskar P. et. al.// IEEE Transactions on Medical Imaging. – 2015. Vol. 34, № 12. – P. 2429–2442.
- 16.Automated approach for detecting tuberculosis using chest radiographs / Sreeja Mole S., Aiswarya A., Akhila L. et. al.// 2015.
- 17.Antani S. Automated detection of lung diseases in chest X-rays // US National Library of Medicine, 2015.
- 18.A novel multiple-instance learning-based approach to computer-aided detection of tuberculosis on chest X-rays / Melendez J., van Ginneken B., Maduskar P. et. al.// IEEE Transactions on Medical Imaging. – 2015. Vol. 34, № 1 – P. 179–192.
- 19.Le K. A design of a computer-aided diagnostic tool for chest X-ray analysis // International Journal of Computer Science and Information Technology. – 2011. Vol. 3, № 2. – P. 212–222.
- 20.Automated cavity detection of infectious pulmonary tuberculosis in chest radiographs / Xu T., Cheng I., Mandal M. // Proc. Annual international conference of the IEEE Engineering in Medicine and Biology Society. – IEEE, 2011. – P. 5178–5181.
- 21.Narayanan B. A novel computer aided detection of identifying lung nodules on chest radiograph. – 2015.
- 22.A comparative study of image segmentation techniques in digital image processing / Verma K.K., Kumar P., Tomar A. et. al.// 2015.
- 23.Al-Amri S.S., Kalyankar N.V. et. al. Image segmentation by using threshold techniques. – 2010. – (Preprint / arXiv).
- 24.Soleymanpour E., Pourreza H.R. et. al. Fully automatic lung segmentation and rib suppression methods to improve nodule detection in chest radiographs // Journal of Medical Signals & Sensors. – 2011. Vol. 1, № 3. – P.191.

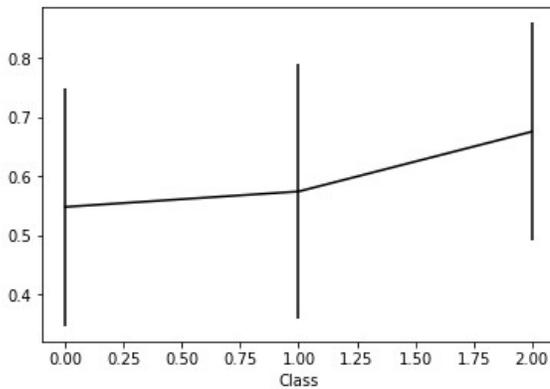
25. Van Ginneken B., ter Haar Romeny B.M. Automatic segmentation of lung fields in chest radiographs // *Medical Physics*. – 2000. Vol. 27, № 10. – P. 2445–2455.
26. Graph-cut based automatic lung boundary detection in chest radiographs / Candemir S., Jaeger S., Palaniappan K. et. al. // *Proc. IEEE Healthcare Technology conference: translational engineering in health and medicine*. – IEEE, 2012. – P. 31–34.
27. Segmentation of anatomical structures on chest radiographs / Juhász S., Horváth Á., Nikhazy L. et. al. // *Proc. XII Mediterranean conference on medical and biological engineering and computing*. - Springer, 2010. – P. 359–362.
28. Towards automatic image segmentation using optimised region growing technique / Alazab M., Islam M., Venkatraman S. // *Proc. Australasian joint conference on artificial intelligence*. – Springer, 2009 – P. 131–139.
29. An improved image segmentation approach based on level set and mathematical morphology / Li H., Elmoataz A., Fadili J.M., Ruan S. // *Proc. Third international symposium on multispectral image processing and pattern recognition*. International Society for Optics and Photonics. – 2003. – P. 851–854.
30. Segmenting anatomy in chest X-rays for tuberculosis screening / Karargyris A., Antani S., Thoma G. // *Proc. Annual inter-national conference of the IEEE Engineering in Medicine and Biology Society*. – IEEE, 2011. – P. 359–362.
31. Dawoud A. Fusing shape information in lung segmentation in chest radiographs // *Proc. International conference image analysis and recognition*. – Springer, 2010. – P. 70–78.
32. A region based active contour method for X-ray lung segmentation using prior shape and low level features / Annangi P., Thiruvenkadam S., Raja A. et. al. // *Proc. IEEE international symposium on biomedical imaging: from nano to macro*. – IEEE, 2011. – P. 892–895.
33. Image segmentation for lung region in chest X-ray images using edge detection and morphology / Saad M.N., Muda Z., Ashaari N.S. et. al. // *Proc. IEEE international conference on control system, computing and engineering (ICCSCE)*. – IEEE, 2014. – P. 46–51.
34. Automatic lung field segmentation in X-ray radiographs using statistical shape and appearance models / Li X., Luo S., Hu Q. et. al. // *Journal of Medical Imaging and Health Informatics*. – 2016. Vol. 6, № 2. – P. 338–348.
35. An edge-region force guided active shape approach for automatic lung field detection in chest radiographs / Xu T., Mandal M., Long R. et. al. // *Computerized Medical Imaging and Graphics*. – 2012. Vol. 36, № 6 – P. 452–463.

36. Segmentation of pathological lungs from CT chest images / Soliman A., Elnakib A., Khalifa F. et. al. // Proc: IEEE international conference on image processing (ICIP). – IEEE, 2015. – P. 3655–3659.
37. Automatic lung segmentation using control feedback system: morphology and texture paradigm / Noor N.M., Than J.C., Rijal O.M. et. al. // Journal of Medical Systems. – 2015. Vol. 39, № 3. – P. 1–18.
38. Ngo T.A., Carneiro G. Lung segmentation in chest radiographs using distance regularized level set and deep-structured learning and inference // Proc. IEEE international conference on image processing (ICIP). – IEEE, 2015. – P. 2140–2143.
39. Rossi F., Rahni A.A.A. Combination of low level processing and active contour techniques for semi-automated volumetric lung lesion segmentation from thoracic ct images // Proc. IEEE student symposium in biomedical engineering and sciences (ISSBES). IEEE, 2015. – P. 26–30.
40. Iakovidis D.K., Savelonas M. Active shape model aided by selective thresholding for lung field segmentation in chest radiographs. Proc. 9th international conference on information technology and applications in biomedicine. – IEEE, 2009. – P. 1–4.
41. Gonzales R.C., Woods R. E. Digital Image Processing. – third edition. – 2008.
42. Tanbakuchi A. Comparison of OpenCV Interpolation Algorithms // [Электронный ресурс] – 2016-02-21 – <http://tanbakuchi.com/>
43. elastix: A Toolbox for Intensity-Based Medical Image Registration // Klein S., Staring M., Murphy K. et. al. // IEEE Transactions on Medical Imaging – 2010. Vol. 29 № 1.
44. ImageNet Classification with Deep Convolutional Neural Networks // Krizhevsky A., Sutskever I., Hinton G.E. // Advances in neural information processing systems – 2012. Vol. 25, №2.
45. U-Net: Convolutional Networks for Biomedical Image Segmentation // Ronneberger O., Fischer P., Brox T. // Proc. International Conference on Medical Image Computing and Computer-Assisted Intervention – Oct. 2015.
46. Fully Convolutional Networks for Semantic Segmentation // Long J., Shelhamer E., Darrell T. // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2016. Vol. 39, № 4. – P. 1.
47. Sharma G., Goodwin J. Effect of aging on respiratory system physiology and immunology // Clinical Interventions in Aging – Published online – Sept. 2006. Vol. 1, № 3 – P. 253–260.

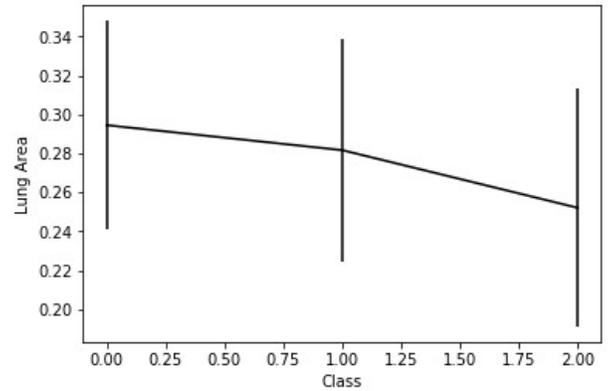
48. Rethinking the inception architecture for computer vision / Szegedy. C., Vanhoucke. V., Ioffe. S.J. et. al. // Proc. IEEE conference on computer vision and pattern recognition (CVPR'2016). – Las Vegas, Nevada, USA, Jun. 26 – Jul. 1, 2016 – P. 2818–2826.
49. Local binary patterns and its application to facial image analysis: a survey / Huang. D., Shan. C., Ardabilian. M. et. al. // IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews). – 2011. Vol. 41, № 6. – P. 765–781.
50. Classification of SURF image features by selected machine learning algorithms / Horak. K., Klecka. J., Bostik. O. et. al. // 40th International Conference on Telecommunications and Signal Processing (TSP'2017). – Barcelona, Spain, Jul. 5-7, 2017. – P. 636–641.
51. Coupled dynamics of body mass and population growth in response to environmental change / Ozgul. A., Childs. D., Oli. M.K. et. al. // Nature. – 2010. Vol. 466, №7305. – P. 482.
52. Pahal P., Sharma S. Emphysema // StatPearls Publishing.
53. Albrechtsen F. Statistical Texture Measures Computed from Gray Level Cooccurrence Matrices // Published online – Jan. 1995
54. A Study on Discrete Wavelet Transform based Texture Feature Extraction for Image Mining / Karthikeyan T., Manikandaprabhu P., Manikandaprabhu J.P. et. al., International Journal of Computer Technology & Applications. Vol. 5, № 5. – P. 1805-1811.
55. Speeded-Up Robust Features (SURF) / Bay H., Ess A., Tuytelaars T., Van Gool L. // Published online — Sep. 2008.
56. Schmitt D., McCoy N. Object Classification and Localization Using SURF Descriptors // Published online — Dec. 2011.
57. Gunn S.R. / Support Vector Machines for Classification and Regression // Published online — Jan. 1998.
58. Biau G. Analysis of a Random Forests Model // Journal of Machine Learning Research. – 2012. Vol. 13 – P. 1063-1095.
59. KNN Model-Based Approach in Classification / Guo G., Wang H., Bell D. et. al. // Published online — Aug. 2004.

ПРИЛОЖЕНИЕ А

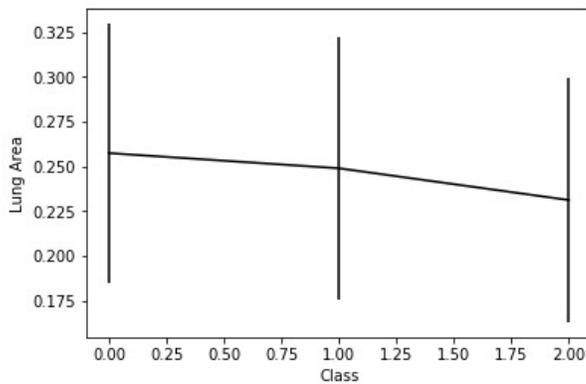
Зависимость между суммой интенсивностей пикселей и возрастной группой



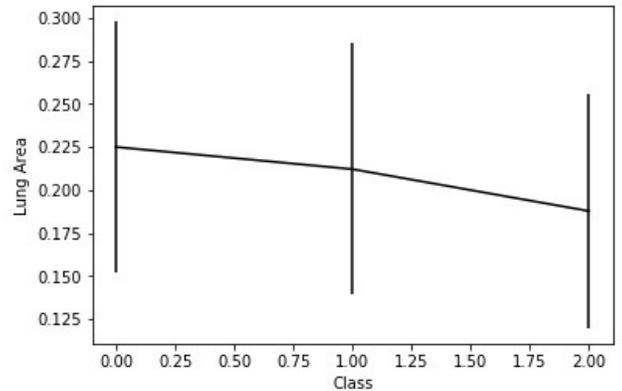
Сумма пикселей на исходных изображениях



Сумма пикселей (площадь) на маске, полученной алгоритмом сегментации



Сумма пикселей (площадь) на маске, полученной AlexNet



Сумма пикселей (площадь) на маске, полученной U-Net