

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ

федеральное государственное бюджетное образовательное учреждение
высшего образования

«Тольяттинский государственный университет»

Институт математики, физики и информационных технологий

Кафедра «Прикладная математика и информатика»

02.03.03 МАТЕМАТИЧЕСКОЕ ОБЕСПЕЧЕНИЕ И АДМИНИСТРИРОВАНИЕ
ИНФОРМАЦИОННЫХ СИСТЕМ

ТЕХНОЛОГИЯ ПРОГРАММИРОВАНИЯ

БАКАЛАВРСКАЯ РАБОТА

на тему

**«Разработка алгоритма дифференциации патологий на растровых
изображениях рентгенограмм»**

Студент	Д. А. Низямов	_____
Руководитель	М. Г. Лисовская	_____
Консультант по аннотации	А. В. Кириллова	_____

Допустить к защите

Заведующий кафедрой А. В. Очеповский _____

« _____ » _____ 20 ____ г.

Тольятти 2017

АННОТАЦИЯ

Темой данной выпускной квалификационной работы является «Разработка алгоритма дифференциации патологий на растровых изображениях рентгенограмм».

Работа выполнена студентом Тольяттинского Государственного Университета, института математики, физики и информационных технологий, группы МОБ – 1301, Низямовым Данилом Александровичем.

Объектом исследования при написании работы стало изучение методов разработки программного обеспечения с использованием языка программирования Matlab.

Предметом исследования работы стало изучение методов разработки программного обеспечения для разработки приложения классификации входных изображений на два класса норма или патология.

Целью является разработка приложения для классификации входных изображений на два класса норма или патология.

В дипломную работу входит введение, три главы, итоговое заключение.

Во введении обосновывается актуальность выбранной темы, ставится цель и определяется примерный план действий для реализации задуманного.

В первой главе описываются существующие методы лучевой диагностики, выделяются их плюсы и минусы. Описывается ручной анализ рентгенографических снимков, и приводятся основные понятия и термины. Описывается способ автоматизации анализа снимков.

Во второй главе описывается процесс разработки алгоритма для автоматизации анализа рентгенографических снимков.

В третьей главе показывается реализация алгоритма, тестирование и оценка работы классификатора.

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

Практическая ценность дипломного проекта заключается в том, что разработанное приложение можно использовать в качестве упрощения работы медицинского персонала при анализе диагноза пациента.

Данное приложение можно охарактеризовать весьма эффективным методом классификации изображений по типам: норма или патология.

Объём дипломной работы 52 страниц, на которых размещены 13 рисунков и 2 таблицы. При написании данной работы использовалось 20 источников.

ABSTRACT

The graduation work Development of an Algorithm for Differentiating Pathologies on Raster Images of Radiographs is devoted to the recognition of pathologies on raster images of X-rays. In this graduation work we explore the existing algorithms for image differentiation and develop our own algorithm. The program can detect the presence or absence of pathologies in the input image.

Doctors bring out the presence of pathologies in several stages. This program will facilitate the work of doctors, as it will replace the primary stage of evaluation of the radiograph. Also, it helps to eliminate such negative factors as fatigue, "blurred" eyes and others.

The key issue of the graduation work is the question by what means the application can recognize pathologies in images and then classify them in two categories: "healthy" or "sick". A comparative analysis of the methods of machine learning is carried out.

The algorithm of the program is as follows. Special signs are highlighted in the image. Next, there is a separation of the selected features into groups, using clustering methods. Then the classifier is trained on this data.

The algorithm for highlighting the lung pattern on the image is developed to improve the quality of the classification of images. The essence of it is that their binary mask is overlaid on the input images. This is necessary in order to remove unnecessary portions of the image and leave only the boundaries of the lungs. This can increase the accuracy of pathologies detection. We conduct a reserch of various machine learning methods and then will choose the most appropriate one for our task.

In conclusion, we would like to stress that at the moment the theme of the graduation work is poorly understood. That is why it is of interest to a wide range of readers who are aware of this topic.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	4
Глава 1 Анализ способов дифференциации патологий на растровых изображениях рентгенограмм.....	6
1.1 Обзор существующих методов лучевой диагностики.....	6
1.2 Ручной метод оценки изображения.....	11
1.3 Автоматизированное распознавание изображений.....	12
1.4 Формализация требований и постановка задач к разрабатываемому программному обеспечению.....	14
Глава 2 Разработка алгоритма дифференциации патологий на растровых изображениях рентгенограмм.....	16
2.1 Разработка общего алгоритма приложения.....	16
2.2 Алгоритм выделения признаков.....	20
2.3 Анализ и сравнение методов машинного обучения.....	24
2.4 Машина опорных векторов.....	27
2.5 Выделение границ легочного рисунка на изображении.....	30
Глава 3 Практическая реализация алгоритма.....	34
3.1 Оценка работы классификатора.....	34
3.2 Программная реализация алгоритма.....	38
3.3 Программная реализация выделения легких.....	40
3.4 Тестирование.....	43
ЗАКЛЮЧЕНИЕ	45
СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ	46
ПРИЛОЖЕНИЕ А	48
ПРИЛОЖЕНИЕ Б.....	52

ВВЕДЕНИЕ

Стремительное развитие новых технологий и инструментальных средств диагностической визуализации обусловлено современными потребностями человечества в появлении новых систем и методов, расширяющих возможности клинического мониторинга и улучшающих качество жизни людей.

Значительное повышение технического уровня развития современных не инвазивных диагностических систем за счет совершенствования аппаратной реализации и технологий производства делает системы диагностической визуализации незаменимыми в повседневной клинической практике. При этом наряду с прогрессом развития инструментальных средств, весьма существенную роль в настоящее время начинают играть компьютерные методы обработки графической информации. Современные методики компьютерной обработки медицинских изображений обеспечивают большие возможности при работе с ними. Это актуализирует проблемы автоматизации медицинские исследования, связанные с обнаружением заболеваний легких. Существует множество болезней, которые можно обнаружить в легких, и почти для всех из них, основным средством диагностики является флюорографический снимок. В основном для определения такой страшной болезни как туберкулеза [2]. Идея данной работы состоит в том, что бы с помощью использования методов машинного обучения, разработать алгоритм отбора патологии при массовых рентгеновских профилактических обследованиях в условиях всеобщей диспансеризации.

Цель выпускной квалификационной работы: разработать приложение для классификации входных изображений на два класса норма или патология.

Объект выпускной квалификационной работы: изучение методов разработки программного обеспечения с использованием языка программирования Matlab.

Предмет исследования выпускной квалификационной работы: изучение методов разработки программного обеспечения для разработки приложение

классификации входных изображений на два класса норма или патология.

Во введении обосновывается актуальность выбранной темы, ставится цель и определяется примерный план действий для реализации задуманного.

В первой главе описываются существующие методы лучевой диагностики, выделяются их плюсы и минусы. Описывается ручной анализ рентгенографических снимков, и приводятся основные понятия и термины. Описывается способ автоматизации анализа снимков.

Во второй главе описывается процесс разработки алгоритма для автоматизации анализа рентгенографических снимков.

В третьей главе показывается реализация алгоритма, тестирование и оценка работы классификатора.

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

Глава 1 Анализ способов дифференциации патологий на растровых изображениях рентгенограмм

1.1 Обзор существующих методов лучевой диагностики

В 21 веке широкое развитие и распространение получили такие методы как магнитно-резонансная томография (МРТ), компьютерная томография (КТ) и позитронно-эмиссионная томография (ПЭТ), а также современный метод ПЭТ-КТ, который сочетает в себе компьютерную томографию и позитронно-эмиссионную томографию. Рассмотрим подробнее каждый из них.

Магнитно-резонансная томография (МРТ) – это современный диагностический метод исследования, который дает возможность осматривать внутренности человеческого тела, чтобы обнаружить заболевания, которые трудно диагностируются, или изменения в функционировании органов.

Метод МРТ основан на сильном, постоянном магнитном поле, стремительно изменяющихся локальных магнитных полях и радиочастотной энергии. В МРТ применяют особую аппаратуру, включая мощную ЭВМ, для того, чтобы создавать снимки внутренних органов тела высокого качества.

МРТ обладает рядом преимуществ, но главное из них то, что при проведении исследования, ни врач, ни пациент не подвергаются рентгеновскому облучению. А также изображения исследования МРТ получаются отличного качества, исследование является достаточно информативным и точным.

У каждого метода исследования есть свои недостатки. У метода МРТ можно выделить такие:

1. Довольно много времени необходимо для получения изображений (как минимум, несколько секунд, чаще всего – минуты), что может привести к артефактам от дыхательных движений (это сильно уменьшает эффективность исследования легких).

2. Высокая стоимость аппаратуры и ее использования, а следовательно, и самой процедуры.

3. Особые требования к помещениям, где расположено оборудование (экранирование от помех).

4. Невозможными являются обследования пациентов, страдающих клаустрофобией, а также больных с крупными металлическими имплантатами из немедицинских металлов.

5. Достаточно длительное исследование (занимает около 20-30 минут), при котором пациенту нужно находиться в неподвижном состоянии.

Следующий метод, который следует проанализировать - компьютерная томография (КТ).

Компьютерная томография (КТ) – это метод обследования внутренних органов тела человека путем использования рентгеновского излучения для получения детальных послойных изображений.

У метода исследования компьютерной томографии есть несколько важных достоинств:

1. Исследование КТ высоко информативно, так как можно получить изображение и поперечного, и продольного срезов;

2. Возможность выявления заболевания на ранней стадии;

3. При проведении процедуры нет неприятных ощущений, КТ – не инвазивный метод исследования.

Конечно, при обследовании методом КТ не обходится и без недостатков [11]. Назовем некоторые из них:

1. Существует малая доля вероятности развития раковых заболеваний (принцип функционирования томографа основывается на применении рентгеновского излучения), вследствие получения пациентом слишком большой дозы облучения. Но все же врач назначает компьютерную томографию, если не удалось выявить диагноз другими методами и показания для обследования превышают риск появления прогрессирования заболевания;

2. До того как пройти исследование методом компьютерной томографии, женщинам необходимо сообщить рентгенологу и своему лечащему о возможной беременности, потому что томографию нельзя рекомендовать беременным женщинам, так как существует риск появления патологии в развитии плода;

3. Существует риск появления тяжелых аллергических реакций и побочных действий вследствие введения вещества, содержащего йод, но он очень низкий;

4. Компьютерная томография не может дать информацию о функциональном состоянии тканей и органов, а только лишь об их строении;

5. Метод исследования КТ можно проводить детям исключительно при случае крайней необходимости для установления диагноза, потому что детский организм является наиболее чувствительным к воздействию радиации;

6. Не разрешается часто проводить исследование методом компьютерной томографии.

Следующий метод исследования – позитронно-эмиссионная томография (ПЭТ) – это современный диагностический метод организма (ветвь ядерной медицины), который используется при онкологических, неврологических, кардиологических и других отраслях медицины.

Позиционно-эмиссионная томография – современный метод исследования организма, он обладает высокой точностью, может заменить собой несколько различных исследований, и одно из наиболее важных его преимуществ для человека - процедура практически безвредна для здоровья.

Недостатками данного исследования тела человека можно считать высокую стоимость процедуры, а также то, что в чистом виде этот метод не может точно определить локализацию опухолей. Именно по этой причине на практике чаще всего используется метод КТ.

Позитронно-эмиссионная томография, совмещенная с компьютерной томографией (ПЭТ-КТ) – это новейший, перспективный метод радионуклидных

исследований различных отклонений в функциях организма и определения патологий со стороны сердечно-сосудистой, нервной, а также легочной систем.

ПЭТ-КТ легких – это современный чувствительный метод исследования организма. Рак легких может стать причиной многочисленных летальных исходов во всем мире. Позитронно – эмиссионная томография за свою историю применения помогла врачам выявить большое количество различных опухолей.

Одним из главных плюсов метода исследования ПЭТ-КТ является возможность отличить злокачественное новообразование от воспалительных процессов в организме человека, может выявить метастазы, а также точное нахождение опухолей.

Метод ПЭТ-КТ хоть и является уникальным, но и у него есть свои недостатки, такие как:

1. ПЭТ-КТ недостаточно информативен при диагностировании некоторых органов вследствие специфического метаболизма глюкозы;
2. Не достаточно результативным ПЭТ-КТ окажется в период после операции вследствие воспалительных процессов, воспринимающиеся как новообразования.

Приведенные выше методы хоть и являются современными и информативными, но чаще всего первичным является исследование, которое рекомендуют проходить врачи – это рентген.

Стоит подробнее рассмотреть данный метод исследования. Рентгенография – это незаменимый метод диагностики, который основан на получении фиксированного снимка на специальной пленке или экране компьютера. С помощью рентгена, исследуют почти все участки тела. Наиболее часто изучаемым объектом рентгенографии являются органы грудной клетки, в том числе – лёгкие.

Данному методу исследования легких не нужна специальная подготовка больного. Процедура исследования методом рентгенографии является довольно быстрой, что позволяет достаточно оперативно провести диагностику пациента.

Чаще всего пациенту назначается рентгенографический метод исследования легких, в случае, если у него имеются различные признаки дисфункций данных органов. Это могут быть такие недуги, как: продолжительный кашель, появление мокроты (в том числе с кровью) в достаточно большом количестве, частой боли в груди, которая, возможно, может отдавать в спину, а также подозрение на воспаление легких, миокардит, артрит. Еще одним показанием к назначению данной процедуры является высокая продолжительная температура тела человека, перелом ребер или наличие признаков сердечной недостаточности. Кроме того в настоящее время нужно регулярно проходить флюорографию легких.

Рентгенография обладает многочисленными преимуществами [15]. Назовем некоторые из них :

1. Рентген является доступным для всех слоев населения;
2. Данный метод исследования довольно информативен;
3. Рентгенография имеет достаточно высокое пространственное разрешение;
4. Для того чтобы диагностировать организм не требуется особая подготовка;
5. Рентгеновские изображения возможно хранить довольно долго для того, чтобы следить за динамикой лечения и выявлять осложнения;
6. У различных специалистов есть возможность оценивать снимок, а не только у рентгенологов.

Конечно, нельзя не упомянуть и про основной, самый очевидный недостаток данной процедуры – это вредоносные ионизирующие излучения. Но стоит отметить тот факт, что существенный вред организму человека может нанести только частое посещение рентгенографии, так как при однократной процедуре вред минимален.

Следовательно, рентгенография – отличный информативный метод диагностики организма человека, который поможет в выявлении многих серьезных заболеваний.

1.2 Ручной метод оценки изображения

Рентгеновское изображение представляет собой снимок, сделанный в негативе. Врачу-рентгенологу, как правило, за день приходится просматривать большое количество рентгенограмм. Не все изображения имеют хорошее качество, некоторые снимки перекошены из-за неправильной установки пленки, на других обрезаны границы и размер самих снимков мал.

Некоторые пациенты игнорируют требования врача о глубоком вдохе и задержке дыхания, меняют свое положение после того, как врач их правильно поставил к монитору. Все это затрудняет исследование изображений.

При анализе рентгеновского снимка врачи анализируют следующие области:

1. Участки просветлений и затемнений;
2. Отсутствие очаговых и инфильтративных теней;
3. Проверяют на предмет нарушения в системе циркуляции и кровоснабжения;
4. Отсутствие кистозных образований, застойных эффектов;
5. Структуры корней легких, их размеры, тяжесть, лимфатические узлы;
6. Усиление рисунка, фиброзы;
7. Кальцинаты;
8. Изменения со стороны диафрагмы.

Оценка одного снимка происходит в два шага. На первом этапе просматривается снимок, устанавливается предварительный диагноз. На втором шаге еще раз происходит оценка снимка и уже пишется заключение.

Это позволяет исключить такие негативные эффекты как, усталость, «замыленность» глаза и другие.

Поэтому качественный и правильный анализ рентгенограммы представляет собой настоящее искусство и воплощает в себе умения распознать даже самые малые изменения в яркости точек на изображении. Все это требует высокой квалификации и многолетнего опыта работы. Так же восприятие изображения у всех разное.

1.3 Автоматизированное распознавание изображений

В современном мире становится достаточно распространенным процессом превращение традиционных рентгенограмм в цифровой массив, который можно обрабатывать с помощью методов вычислительной техники. Аналоговые системы часто могут иметь довольно серьезные ограничения на экспозицию, что происходит по причине маленького динамического диапазона рентгеновской пленки.

Аналоговые и прямые цифровые рентгенографические системы отличаются тем, что второе делает возможным получение диагностических изображений без промежуточных носителей, и что не маловажно - при каком угодно требуемом уровне доз. К тому же, данное изображение возможно обработать и отобразить множеством различных способов.

Использование электронно-вычислительных машин значительно уменьшает трудовые затраты работников и увеличивает точность измерений при анализе рентгенограмм.

Наиболее актуальной является проблема автоматического анализа медицинских изображений, особенно в тех условиях, которые необходимы для проведения обязательного диспансерного обследования населения [13].

Чтобы решить эту проблему, каждому объекту задачи распознавания образов следует быть описанным при помощи некоего набора признаков. К

примеру, в том случае, если ставят задачу постановки диагноза, то медицинский специалист будет заинтересован в таких признаках на рентгенограмме, как затемнения и светлые пятна. На случай если объект охарактеризован d признаками, то его могут анализировать как точку в d -мерном пространстве.

Так, одновременно с понятиями пространства признаков, одним из наиболее важных параметров задач распознавания образов представляется используемое количество классов. Каждый из них необходимо определить так, чтобы любое наблюдение относилось лишь к одному классу. В частности, при установке диагноза автоматически, любого пациента можно отнести или к группе “больных”, или к группе “здоровых”. В данном случае считается, что есть задача бинарной классификации.

Первое, что может заинтересовать исследователя – это разработка диагностического правила, позволяющего определить наличие определенного заболевания у пациента, который в очередной раз поступил в больницу. При этом нужно приготовить схожие данные по здоровым клиентам, и далее при помощи особых математических алгоритмов и методов “обучить” классификатор, чтобы он мог распознавать тот факт, относится ли очередной обследуемый пациент к “имеющим заболевание” или “здоровым”. Ход разработки данного диагностического правила называют “обучением с учителем”, так как нужно иметь выборки объектов с предварительно известными классами. Классификатор может “обучаться” с помощью этой информации и строить итоговое правило, которое позволит определить класс каждого следующего объекта, которые не входят в обучающие выборки. Итоговое правило возможно представить наглядно как поверхность в пространстве признаков. Чтобы отнести объект в какой-либо из этих классов, необходимо знать, с какой из сторон данный объект будет от разделяющих поверхностей в пространстве признаков.

1.4 Формализация требований и постановка задач к разрабатываемому программному обеспечению

Программное обеспечение для дифференциации патологий на растровых изображениях рентгенограмм будет состоять из следующих шагов.

Загрузка обучающей выборки рентгенографических снимков в прямой проекции. Разделение ее на обучающую и проверочную выборку (для применения кросс – валидации).

Выделение признаков на изображениях, таких как: контуры, углы, пятна. Описание объектов с помощью них. Все признаки должны быть достаточно устойчивыми к таким действиям как вращение, перемещение и масштабирование объекта.

Применение алгоритмов кластеризации для схожих признаков. Это поможет соединить похожие признаки одного класса по группам. В качестве них будет выступать их центр кластера.

Классификация изображений по двум классам норма и патология. Такая задача называется бинарной классификацией. Пусть задано множество объектов X , множество меток $Y = \{0, 1\}$, и существует целевая функция $y^*: X \rightarrow Y$, значения которой $y_i = y^*(x_i)$ известны только на конечном подмножестве объектов $X_1, \dots, X_n \in X$. Пары «объект-ответ» (X_i, y_i) называются прецедентами. Совокупность пар $(X_i, y_i)_{i=1}^n$ называется обучающей выборкой. Задача обучения по прецедентам заключается в том, чтобы по обучающей выборке научиться восстанавливать зависимость y^* , то есть построить решающую функцию $X \rightarrow Y$, которая бы приближала целевую функцию $y^*(x)$, причем не только на объектах обучающей выборки, но и на всем множестве X . Кроме того, решающая функция должна допускать эффективную компьютерную реализацию. Каждый объект X_i задается измерениями некоторых своих характеристик – признаков. Допустим, признаков всего m штук. Тогда каждому объекту $X_i \in X$ соответствует вектор

$(X_i^1, \dots, X_i^m)$ – признаковое описание. Таким образом обучающую выборку можно представить в виде матрицы $X \in R^{n \times m}$.

Выделение легких на рентгенографическом снимке для повышения точности классификации. Осуществляться будет с помощью морфологических операций на изображении.

Исходя из объекта и предмета исследования и учитывая особенности существующих аналогов, на основе формализованных требований к разрабатываемому программному обеспечению для достижения поставленной цели были определены следующие задачи:

- 1) изучить методы классификации изображений;
- 2) разработать алгоритм для классификации рентгенографических снимков;
- 3) разработать программный код для классификации рентгенографических снимков с использованием языка технических расчетов MATLAB;
- 4) протестировать и оценить работу программного обеспечения для классификации рентгенографических снимков.

В ходе выполнения выпускной квалификационной работы должно быть разработано программное обеспечение для классификации рентгенографических снимков.

В данной главе были рассмотрены существующие методы лучевой диагностики. Выбран наиболее подходящий метод для автоматизации. Рассмотрен метод ручной оценки рентгенографических снимков. Способы автоматизации данного процесса. Осуществлена формализация требований к программному обеспечению.

Глава 2 Разработка алгоритма дифференциации патологий на растровых изображениях рентгенограмм

2.1 Разработка общего алгоритма приложения

Автоматический анализ как термин медицинской диагностики означает автоматическую классификацию, или распознавание изображений в частных случаях. Изображение относится к определенной группе или классу, как пример – норма или патология. Классификация в математической сути понимается как отыскание некой функции, которая должна отображать множество изображений в таком множестве, элементы которого и представляются классами или группами изображений.

Процесс автоматической классификации чаще всего проходит в три этапа:

К первому этапу относятся предварительные обработки, которые представляют собой максимальное приведение рассматриваемых изображений к эталонным или нормализованным. Часто в медицинских изображениях это бывают различные сдвиги, изменения яркости, а также изменения контраста и преобразования геометрии (перемена масштаба, отклонение оси).

Второй этап относится к выделению признаков, с помощью которых функцию, которая представляет собой обработанное изображение, подвергают функциональному преобразованию, которое выделяет достаточно много наиболее значительных признаков, кодирующихся действительными числами. Выделения признаков заключаются в многочисленных математических преобразованиях изображения.

Третий этап представляет собой классификации признаков. Тот набор действительных чисел, который в итоге мы получили из предшествующих операций и который описывает выделенные признаки, сравнивают с эталонными числами, которые заложены в память машины. Электронно-вычислительная машина, в результате такого сравнения, может

классифицировать изображения, т. е. относить их к какому-либо из общеизвестных видов, к примеру, норма или патология.

Однако есть несколько обстоятельств, слишком затрудняющих выполнение двух крайних этапов автоматической классификации, такие как:

- 1) отсутствие эталона нормы по причине отдельных особенностей любого организма;

- 2) нереальность образования эталона патологии при том, что существует очень большое разнообразие ее форм.

Следовательно, полная автоматическая классификация на данный момент не является возможной при дифференциальной диагностике. Следует отметить, что может быть осуществлен лишь предварительный отбор по принципу норма-патология, которые заменяют собой начальный шаг в оценке изображения. Несмотря на это, данный шаг будет очень полезным в том случае, когда проводятся массовые диспансерные обследования.

Для решения задачи автоматической классификации изображений были разработаны блок – схемы алгоритма обучения представлена на рисунке 2.1 и классификации изображений представленная на рисунке 2.2.



Рисунок 2.1 – Блок-схема алгоритма обучения

Обучение классификатора состоит из:

- загрузки базы с изображениями для обучения классификатора;
- проверки типа изображений;
- выделения признаков методом SURF;
- кластеризации методом *k-means*;
- генерации словаря из кластеров.



Рисунок 2.2 – Блок-схема алгоритма классификации

Распознавание изображения состоит из:

- загрузки изображения;
- проверки типа изображений;
- выделения SURF признаков;
- сопоставления со словарем;
- классификации изображения.

2.2 Алгоритм выделения признаков

Распознавание объектов в области компьютерного зрения является задача нахождения особых образов на изображении или видеопоследовательности. Выделение признаков объектов будет осуществляться с использованием функции «Bag of Features» пакета Matlab .

Основная идея алгоритма, была взята из известной модели по обработке текстовых документов «Bag-of-Words». В данном алгоритме снимки будут рассматриваться как текстовые документы, описание ключевых точек и областей изображения, будет представляться словами из которых будет образовываться документ. Класс документа будет рассчитываться путем вычисления частоты появления ключевых слов.

Для того чтобы описывать объекты на изображении, применяют разнообразные признаки, такие как: контуры, области интереса, пятна. В контексте распознавания образов и визуальной категоризации очень важно то, чтобы эти признаки оказались достаточно устойчивыми к таким действиям, как вращение, перемещение и масштабирование объекта. К тому же, большую роль играет описание выбранных признаков, потому как именно оно находит тип применяемого классификатора. Так, зачастую одной из самых важных частей каждого алгоритма распознавания виртуальных объектов на изображениях - это выбор способа обнаружения, а также и изложения признаков.

Сейчас существуют многочисленные методы описания признаков(дескрипторов) на изображение, такие как: SURF (Speeded Up Robust Features), complex features, Gaussian derivatives, phase-based local features, SIFT (Scale-invariant feature transform), автоматическая селекция масштаба и другие. Также приводились итоги сравнений и оценок популярнейших методов выделения признаков, в соответствии с которыми SIFT и SURF имеют наилучшие показатели [16, 17]. С помощью SIFT можно получить возможность обнаружить множество признаков, однако при этом преимуществе он не отличается выдающейся скоростью выполнения. Опыты показывают нам тот

факт, что SURF показывает наилучшие результаты в качестве обработки изображения достаточно высокого разрешения. Так же данный метод имеет высокую скорость нахождения признаков. SURF лучше всего подходит для нашей задачи по классификации рентгеновских снимков, т.к. они имеют высокое разрешение и метод имеет хорошую скорость обработки изображений.

Детектор SURF основывается на вычислениях матрицы Гессе с простой аппроксимацией. Для каждой точки $P=(x,y)$, матрица Гессе $H(P,\sigma)$ на P с масштабом σ определяется по следующей формуле :

$$H(P,\sigma)=\begin{bmatrix} L_{xx}(P,\sigma) & L_{xy}(P,\sigma) \\ L_{xy}(P,\sigma) & L_{yy}(P,\sigma) \end{bmatrix} \quad (2.1)$$

где $L_{xx}(P,\sigma), L_{yy}(P,\sigma), L_{xy}(P,\sigma)$ – свертка второй производной Гаусса

$\frac{\partial^2}{\partial x^2} g(\sigma), \frac{\partial^2}{\partial y^2} g(\sigma), \frac{\partial^2}{\partial x \partial y} g(\sigma)$ с изображением в точке P , соответственно.

Для того чтобы сократить время обработки, вторая производная Гаусса примерно вычисляется при помощи использования функции «box filter». Затем детерминант матрицы Гессе используют для того чтобы выбрать координаты точек интереса и масштаба. Точки интереса сосредотачиваются при помощи «подавления не-максимумов» (non-maximum suppression). Так SURF признаки становятся более устойчивыми к масштабированию. Далее SURF производит построение области в виде окружности (или сферы) вокруг отведенной точки интереса, это нужно для того, чтобы определить исключительную ориентацию, следовательно так дает SURF признакам инвариантность к вращению.

Из-за того что SURF определяет точки интереса, руководствуясь локальными признаками, число точек, которое обнаружилось, не фиксировано, а может меняться в зависимости от изображения, даже для одинаковых объектов. Именно из-за этого, не нужно напрямую передавать эти дескрипторы в классификатор для того чтобы осуществить распознавание.

SURF дескрипторы, как мы уже отметили выше, имеют определенную длину (такую как: 64 или 128 элементов), но численность выделенных дескрипторов достаточно большое, может достигать нескольких десятков и меняться в связи с каждым изображением. В классификаторе это затрудняет прямое использование SURF дескрипторов. Для того чтобы решить данную проблему, нужно разрабатывать схему описания объекта на основании выделенных SURF признаков.

В методе «Bag of Features» предусмотрено разделение обнаруженных признаков на изображение по группам. Это определено тем, что визуальные черты, выделенные из одного класса объекта должны иметь сходство. Признаки, которые были получены в процессе анализа одного изображения, в то же время могут быть схожими. Распределение признаков по группам может позволить «соединять» похожие признаки вместе и выбирать одного «представителя» для целой группы. В таком случае, описание объекта возможно осуществить при помощи лишь этих «представителей».

Для разделения признаков на кластеры воспользуемся одним из наиболее популярных C K-means, потому что он имеет приемлемую скорость работы и простоту в реализации.

K-means разделяет множества элементов векторного пространства на предварительно определенное число кластеров k . Главная идея - это то, что на всех итерациях еще раз вычисляется центр масс для каждого из кластеров, которые были получены на предшествующем шаге, далее векторы разбивают на кластеры снова основываясь на том, какой из очередных центров стал ближним по выбранной метрике. Алгоритм может завершиться тогда, когда на какой-либо итерации не происходят перемены кластеров. Окончание работы алгоритма произойдет за конечное количество итераций, потому как число допустимых разделений конечного множества ограничено, и на каждом последующем шаге суммарное квадратичное отклонение точек убавляется, из-за этого заикливание становится невозможным. K-means старается привести к

минимуму суммарное квадратичное отклонение точек кластеров от центров данных кластеров:

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} (x_j - \mu_i)^2 \quad (2.2)$$

где k – число кластеров,

S_i – полученные кластеры,

μ_i – центры масс векторов $x_j \in S_i$,

x – набор входных векторов.

При использовании K-means кластеризации необходимо сначала задавать численность кластеров. В том случае, если кластером считают множества однозначных слов (как в текстовом документе), то число кластеров является общим числом «ключевых слов». Это ключевое слово является центром масс каждого из этих кластеров, а множество ключевых слов, которые мы получили, составит словарь. В том случае, если считать, что признаки, которые выделены SURF методом, из объектов определенного класса уникальны и подходят лишь для этого класса объекта, то число слов в словаре (число кластеров), приблизительно равно суммарному числу средних чисел признаков всех классов объекта:

$$K = \sum_{i=1}^N \frac{\sum_{j=1}^{M_i} k_{ji}}{M_i} \quad (2.3)$$

где K – число кластеров,

N – количество классов объектов.

M_i – количество изображений i -ого класса,

k_{ij} – число выделенных признаков из j -ого образца i -ого класса.

По окончании процессов кластеризации получаем набор векторов центра масс каждой группы SURF-дескрипторов. Векторы центра масс – это SURF-дескрипторы, они служат «представителями» для каждого из векторов в

собственной группе. Набор векторов центра масс используют в процессе генерации новых дескрипторов для классификатора.

2.3 Анализ и сравнение методов машинного обучения

Обучение с учителем из области машинного обучения (machine learning) – процесс извлечения информации из уже известных примеров, которое используют для последующих классификаций новых данных. Именно для этого необходимы наборы объектов с предварительно известными классами – их также называют обучающей выборкой. К примеру, для того чтобы предсказать наличие или отсутствие патологии у человека, требуются снимки здорового человека и снимки с отклонением от нормы. Далее создается граница между объектами указанных классов из обучающей выборки во время прохождения процесса обучения классификатора.

Проанализируем задачу обучения с учителем [20]. Пусть X некоторое множество, элементы которого называют *объектами* или примерами, ситуациями, входами (samples), а Y – множество, элементы которого называют ответами или откликами, метками, выходами (responses). Есть некая зависимость (вероятностная или детерминированная), которая позволяет по $x \in X$ предсказывать $y \in Y$. В частности, если зависимость детерминированная, то существует функция $f^* : X \rightarrow Y$. Зависимость является известной лишь на объектах обучающей выборки:

$$\{(x^O, y^O) : x^O \in X, y^O \in Y \mid O = 1, \dots, N\} \quad (2.4)$$

Упорядоченная пара "объект-ответ" $(x^O, y^O) \in X \times Y$ называют прецедентом.

Задачей обучения с учителем является восстановление зависимостей между входом и выходом обучающей выборке, которая у нас уже имеется, то

есть следует построить функцию (решающее правило) $f : X \rightarrow Y$, по новым объектам $x \in X$, которая предсказывает ответ $f(x) \in Y$.

Для того чтобы проверить пригодность использования построенного классификатора в медицинской практике следует оценивать точность предсказания. Именно для этого нужно располагать так называемой тестовой выборкой – дополнительной коллекции образцов с предварительно известным диагнозом, но которые не входили в обучающую выборку. Процесс диагностики образцов сыворотки (объектов) из тестовой выборки проходит посредством последовательного использования обнаруженного решающего правила. Затем по числу ошибок на тестовой выборке можно будет судить о том, насколько применима созданная диагностика заболевания.

Также следует отметить то, что главное правило для оценивания точности классификатора – это то, что никогда не нужно проводить тестирование на объектах из обучающей выборки. Классификатор, в большинстве случаев, с высокой точностью разделяет объекты из обучающей выборки. Однако это совсем не является свидетельством того, что будет достигнута достаточная точность на тестовой выборке и затем на практическом применении.

Самые распространённые алгоритмы машинного обучения, метод опорных векторов, деревья решений, логистическая регрессия, дискриминантный анализ, метод k – ближайших соседей [12]. Давай те подробнее рассмотрим данные методы.

Метод опорных векторов (SVM) – это набор алгоритмов, использующихся для задач классификации и регрессионного анализа. Учитывая, что в N – мерном пространстве каждый объект принадлежит одному из двух классов, SVM генерирует $(N - 1)$ – мерную гиперплоскость с целью разделения этих точек на 2 группы. Это как если бы вы на бумаге изобразили точки двух разных типов, которые можно линейно разделить. Помимо того, что

метод выполняет сепарацию объектов, SVM подбирает гиперплоскость так, чтобы та характеризовалась максимальным удалением от ближайшего элемента каждой из групп.

Дерево решений – это дерево, в листьях которого стоят значения целевой функции, а в остальных узлах – условия перехода, определяющие по какому из ребер идти. Если для данного наблюдения условие истина то осуществляется переход по левому ребру, если же ложь – по правому.

Логистическая регрессия представляет собой мощный статистический способ прогнозирования вероятности возникновения некоторого события с одной или несколькими независимыми переменными. Логистическая регрессия определяет степень зависимости между категориальной зависимой и одной или несколькими независимыми переменными путем использования логистической функции, являющейся аккумулятивным логистическим распределением.

В дискриминантном анализе для определения вероятности принадлежности объекта к одному из двух классов используют линейные функции:

$$\begin{aligned} S_1 &\Leftarrow q_0^1 + q_1^1 + \dots q_m^1 x_m \\ S_2 &\Leftarrow q_0^2 + q_1^2 + \dots q_m^2 x_m \end{aligned} \quad (2.5)$$

Метод ближайшего соседа представляет собой самый простой метрический классификатор, который базируется на оценивании сходства различных объектов. Метод k ближайших соседей позволяет повышать достоверность классификации. Анализируемый объект принадлежит к тому же классу, что и основная масса его соседей, то есть k близких к нему объектов анализируемой выборки X. При решении задач с двумя классами количество соседей будет нечетным, чтобы исключить ситуацию неоднозначности, если одно и то же число соседей будет принадлежать разным классам.

Составим таблицу, в которой отразим основные характеристики классификаторов.

Таблица 2.1 – Основные характеристики классификаторов изображений

Тип классификатора	Прогнозирующая скорость	Использование памяти	Интерпретируемость	Тип предикторов
SVM	Быстрая	Небольшое	Легкая	числовые
Дерево решений	Быстрая	Среднее	Легкая	числовые
Логистическая регрессия	Быстрая	Небольшое	Легкая	числовые
Дискриминантный анализ	Средняя	Небольшое	Легкая	числовые
К-ближайших соседей	Медленная	Среднее	Тяжелая	только евклидово расстояние

Исходя из таблицы 1 наиболее подходящий алгоритм классификации это метод опорных векторов.

2.4 Машина опорных векторов

Решение задачи бинарной классификации при помощи метода опорных векторов заключается в поиске некоторой линейной функции, которая правильно разделяет набор данных на два класса. Рассмотрим задачу классификации на два непересекающихся класса, в которой объекты описываются n -мерными вещественными векторами: $X = R^n, Y = \{-1, +1\}$.

Будем строить линейный пороговый классификатор

$$a(x) \equiv \text{sign}\left(\sum_{j=1}^n w_j x^j - w_0\right) = \text{sign}\langle w, x \rangle - w_0 \quad (2.6)$$

где $x = (x^1, \dots, x^n)$ — признаковое описание объекта x ,

$w = (w^1, \dots, w^n) \in R^n$ и $w_0 \in R$ являются параметрами алгоритма.

Уравнение $\langle w, x \rangle = w_0$ описывает гиперплоскость, разделяющую классы в пространстве R^n . Хотя правило классификации в точности совпадает с моделью нейрона по МакКаллоку-Питтсу, критерий и методы настройки параметров в SVM радикально отличаются от персептронных (градиентных) методов обучения.

Понятие оптимальной разделяющей гиперплоскости, предположим, что выборка линейно разделима, то есть существуют такие значения параметров w, w_0 , при которых функционал числа ошибок

$$Q(w, w_0) \equiv \sum_{i=1}^l \mathbb{I}[\langle w, x_i \rangle - w_0 \leq 0] \quad (2.7)$$

принимает нулевое значение. Но тогда разделяющая гиперплоскость не единственна, поскольку существуют и другие положения разделяющей гиперплоскости, реализующие то же самое разбиение выборки. Идея метода заключается в том, чтобы разумным образом распорядиться этой свободой выбора. Потребуем, чтобы разделяющая гиперплоскость максимально далеко отстояла от ближайших к ней точек обоих классов. Первоначально данный принцип классификации возник из эвристических соображений: вполне естественно полагать, что максимизация зазора (margin) между классами должна способствовать более уверенной классификации.

Заметим, что параметры линейного порогового классификатора определены с точностью до нормировки: алгоритм $a(x)$ не изменится, если w и w_0 одновременно умножить на одну и ту же положительную константу. Удобно выбрать эту константу таким образом, чтобы для всех пограничных (т. е. ближайших к разделяющей гиперплоскости) объектов x_i из X^l

выполнялись условия $\langle w, x_i \rangle - w_0 = y_i$. Сделать это возможно, поскольку при оптимальном положении разделяющей гиперплоскости все пограничные объекты находятся от неё на одинаковом расстоянии. Остальные объекты находятся дальше. Таким образом, для всех $x_i \in X^l$,

$$\langle w, x_i \rangle - w_0 \begin{cases} \leq -1, & \text{если } y_i = -1 \\ \geq 1, & \text{если } y_i = +1 \end{cases} \quad (2.8)$$

Условие $-1 < \langle w, x \rangle - w_0 < 1$ задаёт полосу, разделяющую классы. Ни одна из точек обучающей выборки не может лежать внутри этой полосы. Границами полосы служат две параллельные гиперплоскости с направляющим вектором w . Точки, ближайšie к разделяющей гиперплоскости, лежат в точности на границах полосы. При этом сама разделяющая гиперплоскость проходит ровно по середине полосы.

Чтобы разделяющая гиперплоскость как можно дальше отстояла от точек выборки, ширина полосы должна быть максимальной. Пусть x_- и x_+ — две произвольные точки классов -1 и $+1$ соответственно, лежащие на границе полосы. Тогда ширина полосы есть

$$\left\langle \frac{x_+ - x_-}{\|w\|}, w \right\rangle = \frac{\langle w, x_+ \rangle - \langle w, x_- \rangle}{\|w\|} = \frac{w_0 + 1 - (w_0 - 1)}{\|w\|} = \frac{2}{\|w\|} \quad (2.9)$$

Ширина полосы максимальна, когда норма вектора w минимальна. Итак, в случае, когда выборка линейно разделима, достаточно простые геометрические соображения приводят к следующей задаче: требуется найти такие значения параметров w и w_0 , при которых норма вектора w минимальна при условии.

2.5 Выделение границ легочного рисунка на изображении

На флюорограмме представленной на рисунке 2.3 присутствуют не только легкие, но и такие органы как сердце, диафрагма, аорта. Также видны очертания рук, шеи, ключицы за легочной областью.




Рисунок 2.3 – Флюорографический снимок

Для улучшения качества классификации изображений требуется оставить только ту область, которая является для нас наиболее важной. В данном случае – это легкие. При таком подходе мы сможем исключить ложные срабатывания классификатора, потому что некоторые элементы изображения совпадают с яркостью патологий.

Для того чтобы решить проблему с выделением легких мы можем выбрать такие методы, как:

1. Получить бинарное изображение, заменив легкие белым цветом, а остальную область – черным. Далее наложить бинарную маску на исходное изображение;

2. Использовать функции выделения границ, такие как оператор «canny», «sobel», «prewitt».

Рассмотрим второй пункт. Операторы выделения границ очень чувствительны к шуму, именно поэтому они всегда будут детектировать что-то лишнее на изображении. Нам не удастся полностью удалить их, так как вместе с ними удалятся и нужные нам элементы. А следовательно, будет теряться и информативность изображения. Удаление всех ненужных шумов возможно, но это займет слишком много времени. Также не получится создать единый алгоритм для распознавания легких, так как они имеют разные объемы у каждого человека снимки представлены на рисунке 2.4.



Рисунок 2.4 – Примеры снимков с разными объёмами легких

Следовательно, второй способ не подходит для решения данной задачи, потому что он оказывается очень трудоемким и не стабильным для большинства изображений.

Выделение границ легочного рисунка реализовано в несколько этапов.

Блок-схема алгоритма выделения границ легочного рисунка представлена на рисунке 2.5.




Рисунок 2.5 – Блок-схема алгоритма выделения легочного рисунка

Первый способ основывается на получении бинарного изображения. Для его формирования мы должны выбрать порог бинаризации. Здесь возникает проблема, о которой говорилось ранее, что у каждого человека объем легких разный, соответственно, и пороги будут тоже разными [10]. Можно ее решить

с помощью вычисления среднего значения яркости пикселей на изображении. Ведь легкие занимают большую часть на изображении, соответственно, если их объем больше, то и значение будет выше, и наоборот, если объем легких меньше, то и значение ниже. Вычисляя среднее значение яркости пикселей, мы сможем подобрать нужный порог бинаризации для каждого среднего значения. Полученное изображение будет далеко не идеальным. В области легких на местах, где располагаются корни, сосуды, а также на внешних границах ребер останется шум (черные пятна), так как там более сильная интенсивность цвета. Чтобы убрать шум, воспользуемся операций удаления объектов по заданному размеру пикселей. На изображении также присутствуют белые пятна около тела человека, которые имели одни и те же значения с лёгочными полями. Для удаления лишнего и выполнения заливки воспользуемся функцией тотального ослабления яркостных значений вместе с подавлением краевой структуры. Наше бинарное изображение почти готово, осталось только сгладить края в районе ребер. Для этого воспользуемся морфологической операцией «закрытия» полутоновых изображений.

Теперь, когда получена бинарная маска изображения, мы можем ее наложить на исходное изображение. Накладывать будем путем замены пикселей. Если в бинарном изображении встретится 1, то на исходном оно останется без изменения, если встретится 0, то на исходном изображении значение пикселя так же примет 0 (черный цвет).

В данной главе был разработан алгоритм будущего программного обеспечения для дифференциации патологий на снимках. Описан способ выделения особых признаков на изображении. Проведено сравнение методов машинного обучения. Выбран наиболее подходящий. Разработан алгоритм для выделения легочного рисунка на изображении.

Глава 3 Практическая реализация алгоритма

3.1 Оценка работы классификатора

Для оценки качества модели бинарного классификатора существует ряд показателей. Основой проверки является тестовая выборка в которой проставлено соответствие между объектами и их классами [4].

Первым показателем является ассигасу, оно отражает количество правильно принятых решений классификатора.

$$accuracy = \frac{P}{N} \quad (3.1)$$

Где P – количество объектов, по которым классификатор принял правильное решение,

N – размер обучающей выборки.

Для нашего классификатора ассигасу равно 78,6 процентов при принятых правильных решениях равным 35 и общей выборки 44.

Дальнейшие обозначения удобно будет пояснить с помощью таблицы.

Таблица 3.1 – Таблица контингентности

Модель	Опыт	
	Положительный исход	Отрицательный исход
Положительный исход	T_p	F_p
Отрицательный исход	F_N	T_N

Суть обозначений ясна из первых букв английских терминов:

1. True – истинно;
2. False – ложно;
3. Positive – положительный;
4. Negative – отрицательный.

Термины «положительный» и «отрицательный» здесь относятся не к объекту исследования, а к способности диагностирования. Так, при исследовании заболевания положительным исходом будет являться наличие патологии, отрицательным ее отсутствие. F_p и F_N это статистические ошибки, еще их принято называть, как ошибка первого и второго рода соответственно.

Для нашей задачи таблица сопряжённости представлена на рисунке 3.1.

		Model 1	
True class	Норма	5	2
	Патология	1	6
		Норма	Патология
		Predicted class	

Рисунок 3.1 – Матрица точности

Точность (precision) — показывает, сколько из предсказанных позитивных объектов, оказались действительно позитивными и рассчитывается по формуле:

$$precision = \frac{T_p}{T_p + F_p} \quad (3.2)$$

где T_p – истинно положительный результат,

F_p – ложноположительный результат.

Полнота (recall) — показывает, сколько от общего числа реальных позитивных объектов, было предсказано, как позитивный класс:

$$recall = \frac{T_p}{T_p + F_N} \quad (3.3)$$

где T_p – истинно положительный результат,

F_N – ложноотрицательный результат.

F-мера (F-measure) — характеристика, которая позволяет дать оценку одновременно по точности и полноте.

$$F_{measure} = \frac{1}{a \frac{1}{precision} + (1-a) \frac{1}{recall}}, a \in [0, 1] \quad (3.4)$$

Коэффициент a задаёт соотношение весов точности и полноты. Когда $a=0,5$, F-мера придаёт одинаковый вес обеим характеристикам. Такая F-мера называется сбалансированной, или F_1

$$F_1 = \frac{2 \cdot precision \cdot recall}{precision + recall} \quad (3.5)$$

False Positive Rate (FPR) — показывает, сколько от общего числа реальных негативных объектов, оказались предсказанными неверно.

$$fpr = \frac{F_p}{F_p + T_N} \quad (3.6)$$

где F_p – ложноположительный результат,

T_N – истинно отрицательный результат.

Выполним расчёты по данным формулам и получим:

- $Precision = 71,4\%$;
- $Recall = 83,3\%$;
- $F_{measure} = 76,5\%$;
- $FPR = 14,1\%$.

ROC-кривая — график, который позволяет оценить качество бинарной классификации. График показывает зависимость TPR(полноты) от FPR при варьировании порога. В точке (0,0) порог минимален, точно так же минимальны и TPR и FPR. Идеальным случаем для классификатора является проход графика через точку (0,1). Очевидно, что график данной функции всегда монотонно не убывает.

AUC (Area Under Curve) – данный термин даёт количественную характеристику ROC-кривой: чем больше – тем лучше. AUC – эквивалентна вероятности, что классификатор присвоит большее значение случайно выбранному позитивному объекту, чем случайно выбранному негативному объекту. Когда $AUC = 0.5$, то данный классификатор равен случайному.

ROC-кривая и AUC представлена на рисунке 3.2.




Рисунок 3.2 – ROC-кривая и AUC

3.2 Программная реализация алгоритма

В результате выполнения выпускной квалификационной работы в интерактивной среде разработки Matlab представленной на рисунке 3.3 была разработана и реализована программа для классификации изображений по двум классам норма или патология, обладающими характеристиками:

- наличие интуитивно-понятного графического интерфейса пользователя;
- возможность обучить классификатор с нуля;
- возможность загрузки ранее сохранённого обученного классификатора;
- возможность сохранения текущей конфигурации классификатора для дальнейшего его использования;
- отображение матрицы ошибок и среднего значения точности работы классификатора;
- окно для отображения входного изображения и для фильтрованного изображения;
- фильтры, изменяющие разные показатели изображения, для улучшения ручного анализа.




Рисунок 3.3 – Проект приложения в интерактивной среде Matlab

При запуске приложения перед пользователем открывается главное окно программы представленное на рисунок 3.4. Главное окно состоит из кнопок управления и окон для отображения снимков.




Рисунок 3.4 – Главное окно программы

В левой части программы располагаются основные кнопки друг под другом.

Кнопка «Загрузка базы» отвечает за загрузку папки с изображениями, выделения на них признаков, обучения классификатора.

Кнопка «Загрузка mat-файл» позволяет загрузить ранее обученный классификатор и перейти сразу к распознаванию класса входного изображения.

Кнопка «Сохранение mat-файл» позволяет сохранить текущий обученный классификатор, для дальнейшего его использования.

Кнопка «Выбор изображ.» позволяет загружать входное изображение не входящее в обучающую выборку для классификации его к одному из классов. Так же загруженное изображение отобразится в левом окне, а под ним будет отображен класс, к которому оно принадлежит.

Кнопка «Справка» при нажатие появляется диалоговое окно с информацией о программе.

3.3 Программная реализация выделения легких

Выделение легких происходило с помощью бинарной маски. Для ее получения применялись различные морфологические операции представленные на рисунок 3.5




Рисунок 3.5 – Процесс получения бинарного изображения: а – преобразование исходного изображение в бинарное по порогу (функция `BWlabel`), б – заполнение небольших областей на изображении черным (функция `imfill(IM)`), в – удаление шумов(функция `imclearborder(IM)`)

Далее с помощью функции $SE = \text{strel}('disk', R, N)$ создаем плоские дискообразные структурные элементы, где параметр R описывает радиус. R должно быть неотрицательным вещественным числом, в нашем случае это 51. Параметр N принимает значение 8. С помощью функции $\text{imclose}(IM, SE)$ выполняем морфологическое закрытие бинарного изображения представленное на рисунок 3.6.




Рисунок 3.6 – бинарная маска изображения

Затем мы накладываем бинарную маску на исходное изображение с помощью перебора каждого элемента матрицы представленного на рисунок 3.7.

```

[m,n]=size(p1);
t=20;%Уровень черного
a=0;%Цвет для замены (255- белый, 0- черный)
for i=1:m for j=1:n if p1(i,j)<t p2(i,j,:)=a; end; end; end;

```

Рисунок 3.7 – Функция наложения маски на изображение

После завершения операции по замене элементов матрицы мы получаем выделенный легочный рисунок представленный на рисунке 3.7.



Рисунок 3.7 – Изображение после наложения бинарной маски

3.4 Тестирование

Тестирование программного обеспечения является важной частью реализации алгоритма. Данный алгоритм тестировался при следующих условиях.

- База снимков для обучения;
- Рентгеновский снимок с патологией;
- Фильтр установим на «Гамма-коррекция 1.5».

Фильтр «Гамма-коррекция 1.5» позволяет отображать наименьшие значения интенсивности еще меньшими, а наибольшие - еще большими. Если гамма больше 1, а в нашем случае она 1.5, то диапазон с малыми значениями интенсивности растягивается, а диапазон с большими значениями интенсивности сжимается. Благодаря этому мы сможем лучше видеть скрытые затемнения на изображении.

Результат работы программы представлен на рисунке 3.8.




Рисунок 3.8 – Результат работы программы

В ходе работы с приложением была загружена обучающая выборка, обучен классификатор и правильно выделен класс тестового изображения. Так

же была проверена функция сохранения классификатора и дальнейшая его загрузка.

В данной главе произведена оценка работы классификатора. Программно реализован алгоритм классификации изображений по двум классам норма или патология. Проведено тестирование данного алгоритма. Реализован алгоритм выделения легочного рисунка на изображении.

ЗАКЛЮЧЕНИЕ

Целью выпускной квалификационной работы являлась разработка приложения для классификации входных изображений. Создание данного приложения позволяет классифицировать изображения на два класса: норма или патология. На основе анализа состояния вопроса установлено, что автоматизация анализа рентгенографических снимков возможна за счет применения в них алгоритмов машинного обучения.

Были рассмотрены теоритические аспекты и математические методы выделения особых признаков на изображении. Проведено сравнение методов машинного обучения и выбор наиболее подходящего для нашей задачи, в нашем случае таким методом оказался метод опорных векторов. Произведена оценка работы классификатора.

Был разработан алгоритм для выделения легких на рентгенографических снимках, с помощью морфологических операций над изображением.

Была проведена апробация на реальной задаче, которая показала, что использование такого подхода эффективно, и оно позволит ускорить работу медицинского персонала.

Дальнейшее направление исследования будет направлено на совершенствование достигнутого результата, то есть на повышение точности классификации изображений по двум классам: норма и патология.

СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ

Научная и методическая литература

1. Алексеев Е.Р., Чеснокова О.В. MATLAB 7. Самоучитель. Издательство: «НТ Пресс», 2006 г. – 464 стр.
2. Браженко Н.А. Туберкулез органов дыхания. Издательство: СпецЛит, 2012 г. – 368 стр.
3. Васильев, В. В. Практикум по информатике: учеб. пособие / В. В. Васильев, Н. В. Сороколетова. – Гриф УМО. – М.: ФОРУМ, 2009. – 335 с
4. Иглин С.П. Теория вероятностей и математическая статистика на базе MATLAB: Издательство НТУ "ХПИ", 2006 г.– 612 с.
5. Зими́на В.Н., Коше́чкин В.А., Кравче́нко А.В. Туберкулез и ВИЧ-инфекция у взрослых. Руководство. Издательство: ГЭОТАР-Медиа, 2014 г. – 224 стр.
6. Курбатова Е.А. MATLAB 7. Самоучитель. Издательство: Вильямс, 2005 г. – 256 стр.
7. Нгуен Т.Т. Алгоритмическое и программное обеспечение для распознавания фигур с помощью Фурье-дескрипторов и нейронной сети // Известия Томского Политехнического Университета. – Томск: Из-во ТПУ, 2010 г. – 22-125 стр.
8. Татур, Ю.Г. Высшее образование: методология и опыт проектирования : учеб. пособие / Ю. Г. Татур. – Гриф УМО. – М.: Логос, 2006. – 252 с.
9. Труфанов Г.Е. Лучевая диагностика. Учебник. Издательство: ГЭОТАР-Медиа, 2011 г. – 416 стр.
10. Р. Гонсалес, Р. Вудс, С. Эддинс. Цифровая обработка изображений в среде MATLAB. Москва: Техносфера, 2006 г. – 616 стр.
11. Хофер Матиас. Компьютерная томография. Базовое руководство. Издательство: Медицинская литература, 2011 г. – 232 с.

Электронные ресурсы

12. Машинное обучение. Классификация [Электронный ресурс]. – Электрон. дан. – [2017]. – Режим доступа: <http://www.machinelearning.ru/>
13. Авшаров Е. М., Абгарян М. Г., Сафарянц С. А. Обработка медицинских изображений, как необходимый инструментарий медицинского диагностического процесса [Электронный ресурс]. – Электрон. дан. – [2017]. – Режим доступа: www.course-as.ru/download/pdf/Processing_of_medical_images.pdf.
14. MathWorks. MATLAB [Электронный ресурс]. – Электрон. дан. – [2017]. – Режим доступа : <http://matlab.ru/products/matlab>.
15. Медицинская энциклопедия. Флюорография [Электронный ресурс]. – Электрон. дан. – [2017]. – Режим доступа : <http://www.medical-enc.ru/20/fluorography.shtml>.

Литература на иностранном языке

16. Mikolajczyk K., Schmid C. A performance evaluation of local descriptors //IEEE Transactions on Pattern Analysis and Machine Intelligence. – Washington DC: IEEE Society, 2005.
17. Juan L., Gwun O. A comparison of SIFT, PCA-SIFT and SURF // Int. J. Image Process (IJIP). – CSC Journals, 2009.
18. Chawla N., Bowyer K., Hall L., Kegelmeyer W., SMOTE: Synthetic Minority Over-sampling Technique. // Journal of Artificial Intelligence Research, Vol. 16., 2002.
19. Maurice Charbit, Gérard Blanchet. Digital Signal and Image Processing using MATLAB, Volume 1. ISTE Ltd, 2015.
20. Miroslav Kubat. An Introduction to Machine Learning, Springer, Inc., 2015.

ПРИЛОЖЕНИЕ А

Код классификации рентгенографических изображений

```
1 function image_training_interface
2
3 %% Инициализация интерфейса
4
5     gui_state = struct('gui_Name',      mfilename, ...
6                        'gui_Singleton', 0, ...
7                        'gui_OpeningFcn', @opening_func, ...
8                        'gui_OutputFcn',  @output_func, ...
9                        'gui_LayoutFcn',   [], ...
10                       'gui_Callback',   []);
11     gui_state.gui_OutputFcn = @output_func;
12     handles = gui_mainfcn(gui_state);
13
14     function opening_func(obj,~,handles)
15         guidata(obj,handles); %сохраняем ссылки на объекты в handles
16     end
17
18     function handles = output_func(obj,~,handles,varargin)
19         movegui(obj,'center') %расположение окна интерфейса по центру (при
открытии)
20     end
21
22     %% Хранилище переменных
23
24     data = data_storage; %объект класса data_storage
25     data.var.to_disable = [ ...
26         handles.load_base ...
27         handles.load_mat ...
28         handles.save_mat ...
29         handles.select_image ...
30         handles.info ...
31         handles.filter];
32
33     %% Назначим callbacks (функции)
34
35     set(handles.load_base,'Callback', ...
36         @(obj,src)load_base(obj,src,handles,data))
37     set(handles.load_mat,'Callback', ...
38         @(obj,src)load_mat(obj,src,handles,data))
39     set(handles.select_image,'Callback', ...
40         @(obj,src)save_mat(obj,src,handles,data))
41     set(handles.select_image,'Callback', ...
42         @(obj,src)load_img(obj,src,handles,data))
43     set(handles.info,'Callback', ...
44         @(obj,src)show_info(obj,src,handles,data))
45     set(handles.filter,'Callback', ...
46         @(obj,src)filter_img(obj,src,handles,data))
47
48     end
```

```

49
50 function load_base(~,~,handles,data)
51     %% Выключим эл-ты управления на время классификации
52     set(data.var.to_disable,'Enable','off'); drawnow
53     %% Загрузка базы изображений
54     data.var.setDir = fullfile(pwd,'TrainingImages');
55     data.var.BaseImage = imageSet(data.var.setDir,'recursive');
56     %% Разделение выборки
57     [data.var.TrainingBase,data.var.ValidationBase] = partition( ...
58         data.var.BaseImage,0.3,'randomize');
59     %% Выделение признаков
60     data.var.Feature = bagOfFeatures(data.var.TrainingBase);
61     %% Обучение классификатора
62     data.var.Classifyy = trainImageCategoryClassifier( ...
63         data.var.TrainingBase,data.var.Feature);
64     %% Оценка классификатора
65     data.var.MatrixAcc = evaluate(data.var.Classifyy, ...
66         data.var.ValidationBase);
67     set(handles.table, ...
68         'Data',data.var.MatrixAcc, ... %матрицу - в таблицу
69         'ColumnName',data.var.Classifyy.Labels, ...
70         'RowName',data.var.Classifyy.Labels)
71     %% Среднее значение точности классификатора
72     set(handles.mean,'String', ...
73         sprintf('mean = %.2f',mean(diag(data.var.MatrixAcc))))
74     %% Включаем элементы управления обратно
75     set(data.var.to_disable,'Enable','on'); drawnow
76 end
77
78 function load_mat(~,~,handles,data) %загрузка mat файла
79     [f,p] = uigetfile('*.mat','Выбор файла');
80     if ~p; return; end
81     contents = load([p f]);
82     for fld = fieldnames(contents)' %запись содержимого в data.var
83         data.var.(fld{:}) = contents.(fld{:});
84     end
85     set(handles.table, ...
86         'Data',data.var.MatrixAcc, ... %матрицу - в таблицу
87         'ColumnName',data.var.Classifyy.Labels, ...
88         'RowName',data.var.Classifyy.Labels)
89     %% Среднее значение точности классификатора
90     set(handles.mean,'String', ...
91         sprintf('mean = %.2f',mean(diag(data.var.MatrixAcc))))
92 end
93
94 function save_mat(~,~,~,data) %сохранение mat файла
95     [f,p] = uiputfile('*.mat','Сохранить');
96     if ~p; return; end
97     Feature = data.var.Feature; %#ok<*NASGU>
98     BaseImage = data.var.BaseImage;
99     ValidationBase = data.var.ValidationBase;
100    MatrixAcc = data.var.MatrixAcc;
101    TrainingBase = data.var.TrainingBase;

```

```

102     Classifyy = data.var.Classifyy;
103     save([p f], 'Feature', 'BaseImage', 'ValidationBase', 'MatrixAcc', ...
104         'TrainingBase', 'Classifyy')
105 end
106
107 function load_img(~,~,handles,data) %загрузка изображения
108     %% Загрузка исходного изображения
109     [f,p] = uigetfile('*.','Выбор изображения');
110     if ~p; return; end
111     try %попробуем загрузить
112         img = imread([p f]);
113         axes(handles.original) %активные оси - исходное изображение
114         imshow(img) %отобразим
115         cla(handles.filtered) %очистим оси под фильтрованное изображ.
116         set(handles.filter, 'Value', 1)
117         %% Сегментация
118     %     [~,imgs] = segmentImage(img);
119         %% Без сегментации
120         imgs = img;
121     catch
122         return
123     end
124     %% Использование классификатора
125     [Class,~] = predict(data.var.Classifyy, imgs);
126     data.var.img = img; %в переменную
127     %% Вывод класса
128     lbl = data.var.Classifyy.Labels(Class);
129     set(handles.class, 'String', lbl)
130 end
131
132 function show_info(~,~,handles,data) %#ok<INUSD> %справка
133     msgbox( ... %текст по строкам:
134     {'Данное приложение производит классификацию входных изображение на 2
135     класса(Норма\Паталогия)', 'Кнопка "Загрузка базы" отвечает за загрузку обучающих
136     изображений для тренировки классификатора', '"Загрузка .mat" производит загрузку
137     обученного классификатора', 'После того, как вы обучите классификатор или загрузите
138     обученный, при нажатие на кнопку "Выбор изобр." вы сможете загружать изображения и
139     определять их принадлежность к одному из двух классов', 'Ниже кнопки "справка"
140     располагается матрица точности, она показывает какое кол-во изображений от общего числа
141     отнеслись к правильному и неправильному классу ', 'Ниже выводится обученность
142     классификатора от 0 до 1', '"Выбор фильтра" усиливает\изменяет на изображение разные
143     характеристики '}, ...
144     'Справка') %заголовок
145 end
146
147 function filter_img(obj,~,handles,data) %загрузка изображения
148     switch get(obj, 'Value')
149     case {4,5,6}
150         try
151             img = data.var.img;
152         catch
153             %
154         end
155     end

```

```

145     end
146     switch get(obj,'Value')
147         case 1
148             return
149         case 2 %Увеличение яркости
150             img = imadjust(data.var.img,[0 0.6],[]);
151         case 3 %Увеличение контрастности
152             img = imadjust(data.var.img,[0.4 0.6],[]);
153         case 4 %Выпрямление гистограммы
154             img = histeq(img);
155         case {5,6} %Гамма-коррекция
156             img = histeq(img);
157             k = 0.99;
158             SKOI = std2(data.var.img) / 100;
159             sr_znI = mean2(data.var.img) / 100;
160             B1 = (sr_znI - SKOI) * k;
161             B2 = (sr_znI + SKOI) * k;
162             if B2 > 0.999
163                 B2 = 0.999;
164             end
165         end
166     try
167         switch get(obj,'Value')
168             case 5 %Гамма-коррекция 1.5
169                 img = imadjust(img,[B1 B2],[],2.5);
170             case 6 %Гамма-коррекция 4.0
171                 img = imadjust(img,[B1 B2],[],5);
172         end
173     catch
174     end
175     axes(handles.filtered); imshow(img)
176 End

```

ПРИЛОЖЕНИЕ Б

Код выделения легочного рисунка на изображении

```
1  function [BW,maskedImage] = segmentImage(X)
2
3  X = img;
4  Srd = mean2(X) / 255;
5
6  if Srd < 0.27 & Srd > 0.24
7      B = 80;
8  elseif Srd < 0.32 & Srd > 0.27
9      B = 120;
10 end;
11 BW = X > B;
12
13 % Удаление шумов
14 BW = imclearborder(BW);
15
16 % Заливка небольших областей
17 BW = imfill(BW, 'holes');
18
19 radius = 6;
20 decomposition = 6;
21 se = strel('disk', radius, decomposition);
22 BW = imopen(BW, se);
23
24 BW = imfill(BW, 'holes');
25
26 % Наращивание
27 radius = 50;
28 decomposition = 4;
29 se = strel('disk', radius, decomposition);
30 BW = imdilate(BW, se);
31
32 % Закрытие изображения, сглаживание
33 radius = 72;
34 decomposition = 8;
35 se = strel('disk', radius, decomposition);
36 BW = imclose(BW, se);
37
38 % Наложение маски
39 maskedImage = X;
40 maskedImage(~BW) = 0;
41 imshow(maskedImage);
```