МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РФ

Федеральное государственное автономное образовательное учреждение высшего образования
Южно-Уральский государственный университет
(национальный исследовательский университет)

Высшая школа электроники и компьютерных наук
Кафедра вычислительной математики и высокопроизводительных вычислений

ПОЯСНИТЕЛЬНАЯ ЗАПИСКА К ВЫПУСКНОЙ КВАЛИФИКАЦИОННОЙ РАБОТЕ

на тему

Применение методов машинного обучения к задаче поиска аномалий на рентгенографических изображениях легких

Группа КЭ-230
Студент (ФИО) Киселева А.А. _____
Руководитель Турлакова С.У.
доцент кафедры вычислительной математики и высокопроизводительных вычислений, к.ф.-м.н.

Челябинск
2020 г.

АННОТАЦИЯ

Данная выпускная квалификационная работа посвящена предварительной обработке и классификации медицинских изображений с применением нейронных сетей.

Для проведения классификации был изучен процесс анализа флюорографических снимков врачами-рентгенологами, изучены основные методы классификации изображений.

В работе были собраны данные и проведена их предварительная обработка. Описана разработка программы и базы данных, предназначенных для хранения информации о снимках и их характеристиках. Данная программа позволяет извлечь из файла DICOM информацию о результатах проведенного обследования (есть патология / нет патологии).

Приведена постановка задачи классификации медицинских изображений. Сформулировано математическое описание поставленной задачи.

Приведено алгоритмическое и математическое описание удаления обнаружения границ ребер на изображении и удаления реберной ткани. Приведена программа, реализующая данный алгоритм.

Проведены эксперименты с данными: классификация без предварительной обработки, классификация с удалением костной ткани с изображения. Проведена оценка качества приведенных классификаций с использованием F-меры.

Исходя из результатов проведенных экспериментов, сделан вывод о полезности и целесообразности применения метода предварительного удаления реберной ткани с рентгеновских снимков при определении наличия патологий в легких.

Научная новизна исследования состоит в том, что в работе впервые применен метод удаления костной ткани для флюорографических снимков легких, оценена эффективность метода, использованного для предварительной обработки снимков при классификации.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ 4

1. ОПИСАНИЕ ПРЕДМЕТНОЙ ОБЛАСТИ 6

2. ПОСТАНОВКА ЗАДАЧИ 11

3. ОБЗОР МЕТОДОВ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ 15

4. ОБЗОР ПУБЛИКАЦИЙ И ТЕХНОЛОГИЧЕСКИХ РЕШЕНИЙ 26

5. ПОДГОТОВКА ДАННЫХ ДЛЯ ЭКСПЕРЕМЕНТОВ 32

6. УДАЛЕНИЕ КОСТНОЙ ТКАНИ С ИЗОБРАЖЕНИЯ 41

7. КЛАССИФИКАЦИЯ ИЗОБРАЖЕНИЙ 48

8. РЕЗУЛЬТАТЫ ЧИСЛЕННЫХ ЭКСПЕРИМЕНТОВ 51

ЗАКЛЮЧЕНИЕ 56

БИБЛИОГРАФИЧЕСКИЙ СПИСОК 57

ПРИЛОЖЕНИЕ А - Основные теги структуры DICOM файла 63

ПРИЛОЖЕНИЕ Б – Код программы предварительной обработки изображений 67

ПРИЛОЖЕНИЕ В – Код программы удаления реберной ткани и классификации изображений 71

ВВЕДЕНИЕ

Флюорография легких является основным методом первичной диагностики туберкулеза. По данным ВОЗ пропуски заболеваний при диагностировании могут составлять до 10% случаев. Пропуск заболевания туберкулезом несет огромные негативные последствия, так как по статистике один больной туберкулезом в активной фазе может заразить до 11 человек за год. Кроме того, позднее выявление заболевания значительно увеличивает сложность и стоимость лечения. Таки образом, задача определения патологий на снимках легких будет актуальна, пока флюорография является методом диагностики туберкулеза.

Процесс описания флюорографического снимка проходит в 2 этапа. По законодательству снимок обязательно должен быть просмотрен и описан дважды разными врачами. На практике во многих небольших больницах работает только один врач рентгенолог, который проводит чтение только один раз. Особенно это распространено в отдаленных лечебных учреждениях в деревнях и селах. В крупных городских больницах правило двойного чтения так же не всегда может быть выполнено в связи с большим объемом снимков для описания и превышением нагрузки на специалистов. В связи с этим требуется разработка систем, позволяющих снизить погрешности при анализе флюорографических снимков врачом.

Программа автоматической классификации флюорографических снимков не может являться заменой врачу, она должна служить помощником в определении патологий. Если точность компьютерной классификации будет на уровне опытного врача, то процент ошибок в диагностировании по теореме Кондорсе будет значительно ниже.

Целью данной выпускной квалификационной работы является осуществление компьютерной классификации рентгенографических изображений легких по наличию или отсутствию аномалий (патологий) с применением методов машинного обучения.

Для достижения поставленной цели сформулированы следующие задачи:

1. Изучение предметной области и проблемы.
2. Постановка задачи.
3. Обзор методов решения задачи.
4. Обзор публикаций по теме и технологических решений.
5. Сбор и подготовка данных.
6. Обработка данных для повышения качества классификации.
7. Проведение экспериментов.
8. Анализ результатов.

В выпускной квалификационной работе использовались открытые наборы данных рентгенографических снимков легких NIH Chest X-rays Dataset и архив флюорографических снимков Государственного бюджетного учреждения здравоохранения «Челябинский областной клинический противотуберкулезный диспансер».

1. ОПИСАНИЕ ПРЕДМЕТНОЙ ОБЛАСТИ

Описание методов диагностики заболеваний легких

Рентгеноскопия - это метод исследования органов дыхания, который заключается в получении изображения легких с помощью рентгеновских лучей на специальном экране. Этот метод позволяет увидеть различные патологии в легочной ткани, наличие жидкости или воздуха в плевре.

По мнению Браженко Н.А., Серова В.В. и Wang Z. основными преимуществами метода являются:

1. Способность проводить исследования в различных проекциях.
2. Способность оценивать локализацию тех или иных изменений.

При этом основными недостатками метода - невозможно увидеть небольшие очаги патологий; высокая доза облучения.

Флюорография (ФОГ) - это метод исследования грудной клетки с помощью рентгеновских лучей. Результатом этого метода является изображение, которое записывается на особо чувствительную пленку.

Из описания методов можно сделать вывод о схожести методов рентгеноскопии и флюорографии. Отличия этих методов заключаются в применяемой дозе облучения. Флюорография относится к малодозовым методам. На рисунке 1 представлен рентгенографический и флюорографический снимки.

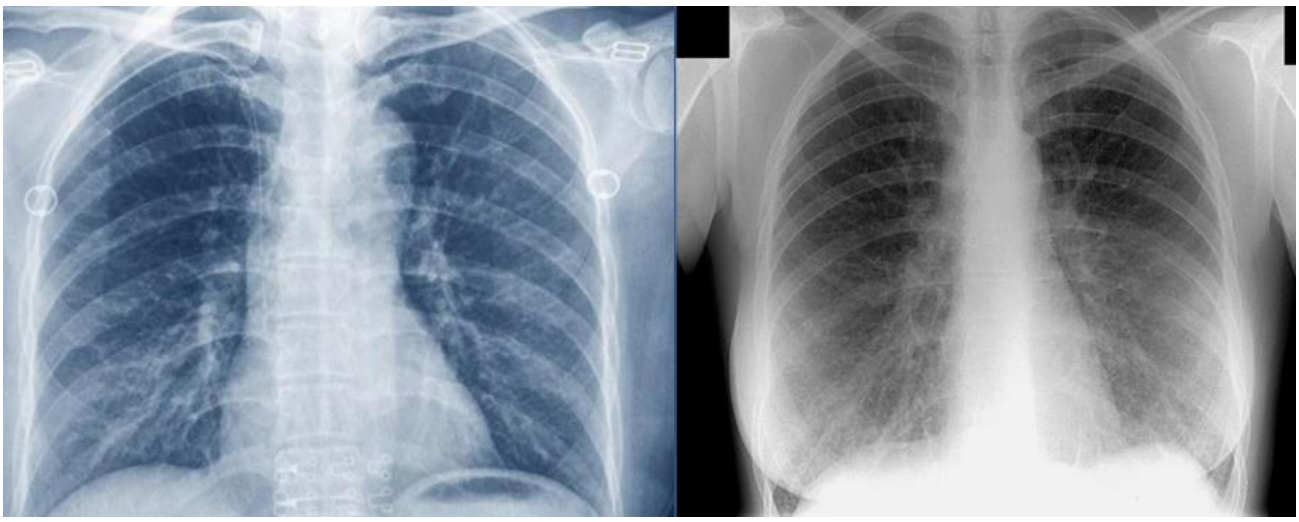

Рисунок 1 – слева - рентген легких; справа – флюорография легких.

Флюорография применяется для выявления наличия патологий на ранней стадии. Флюорография позволяет идентифицировать:

1. Воспаление тканей.
2. Опухоли.
3. Уплотнения и рубцовые трансформации.
4. Инородные тела.

По мнению Саймона Хайкин, Пальцева М.А. и Рябова Г.А. основными преимуществами метода являются:

1. Минимальное количество времени.
2. Более низкое облучение по сравнению с другими рентгеновскими методами.

При этом недостатками метода - высокая степень погрешности при использовании пленочного устройства. Это не позволяет детально рассмотреть патологии. В связи с этим новые флюорографические аппараты, поставляемые в больницы Челябинской области, являются цифровыми, а старые аппараты оснащаются оцифровщиками – дигитайзерами.

Самые распространенные флюорографические аппараты в Челябинской области – это отечественный ПРОСКАН 7000 и французский STEPHANIX. Оба аппарата цифровые и хранят снимки в формате DICOM.

Флюорография и рентгеноскопия являются наиболее распространенными, не требуют много времени. Изображения, полученные с помощью этих методов, имеют достаточный набор информативных признаков для выявления аномалий и классификации.

В связи с этими преимуществами флюорографии и рентгенографии для диагностики патологий легких в данной работе рассматриваются именно эти методы.

Рассмотрим какие именно патологии можно определить с помощью рентгенографии и флюорографии.

Описание патологий, выявляемых с помощью рентгенографии и флюорографии

Среди основных патологий легких Лыткина М.И., Рябов Г.А. и Семенов В.Н. выделяют:

1. Инфильтрацию.
2. Фиброз.
3. Гидроторакс.
4. Ателектаз.
5. Пневмоторакс.
6. Эмфизему [18, с. 63].

Необходимо обратить внимание, что это названия характерных отклонений или аномалий на рентгеновском или ФОГ снимке.

По наличию этих отклонений, врач-рентгенолог может судить о присутствии того или иного заболевания.

Отличительной особенностью многих заболеваний легких является комплексная диагностика. Иными словами, по одним снимкам не ставят диагноз. Диагноз ставят, руководствуясь также результатами других исследований, клинической картины и анамнеза пациента.

Например, пневмония - это воспалительный процесс, возникающий в легких при возникновении инфекции. Рентгеновское изображение характеризуется:

1. Потемнение легочной ткани; контрастность рисунка легких.
2. Увеличение легочного корня на воспаленной стороне.

Туберкулез - широко распространённое в мире инфекционное заболевание человека и животных, вызываемое палочками Коха. Он может проявляться на рентген картине в виде инфильтрации, фиброза, увеличения лимфатических узлов и в виде других аномалий.

Основным методом определения туберкулеза является флюорографическое обследование. Рассмотрим процесс флюорографического обследования более подробно.

Алгоритм описания флюорограммы

Флюорография проводится ежегодно для каждого гражданина Российской Федерации.

Процесс описания флюорографического снимка проходит в 2 этапа. Они называются первое чтение и второе чтение. В ходе них снимок просматривается и описывается двумя разными врачами. Такая мера принята для того, чтобы снизить количество пропусков заболевания.

Приведем самые распространенные варианты описания флюорографических снимков (по данным ГБУЗ «ЧОКПТД»):

1. Без патологии.
2. Сердце и легкие чистые.
3. Сердце и легкие без особенностей.
4. Дообследование.
5. Рекомендован рентген.
6. Остаточные изменения после заболевания…

Пункты 4 и 5 означают, что на снимке выявлена патология, и для дальнейшей ее идентификации необходимо провести дополнительное обследование, чаще всего рентгенографию или компьютерную томографию.

ФОГ обследование служит первичным диагностическим мероприятием, на котором врач определяет, есть патология на снимках или нет. Если патология обнаружена, она не идентифицируется детально, пациент направляется на дополнительное обследование, по которому уже определяется диагноз.

Таким образом, описание флюорографических снимков можно разбить на 2 класса:

1. Без патологических изменений.
2. Патология.

Выводы по разделу 1: Приведен анализ предметной области и методики описания флюорографических снимков. Выявлено, что флюорография является самым быстрым и эффективным методом выявления на ранних стадиях таких заболеваний легких, как туберкулез. Определено, что при описании флюорографического снимка врач-рентгенолог по сути классифицирует снимок как норму или патологию.

2. ПОСТАНОВКА ЗАДАЧИ

Постановка диагноза является классификационной задачей. В рассматриваемом случае диагноз представляет собой констатацию наличия или отсутствия патологического состояния в легких.

В общем случае алгоритмы классификации (распознавания), применяемые в медицинской диагностике, базируются на следующих трех гипотезах [12].

1. Первая состоит в том, что при полноте описания близким описаниям в пространстве признаков должны соответствовать близкие диагнозы.
2. Вторая гипотеза выдвигает предположение о функциональном виде разделимости классов: линейная разделимость, квадратичная разделимость и т. п.
3. Третья гипотеза состоит в предположении существования так называемого диагностического сочетания признаков, встречающихся в одном классе значительно чаще, чем в другом.

Задачу диагностирования заболеваний можно поставить следующим образом.

Введем обозначения:

- D_1 – диагноз «без патологических изменений»;
- D_2 – диагноз «патология».

Пусть для каждого больного имеется совокупность данных, характеризующих его состояние (анамнез, лабораторные исследования и т. д.) $x_1, x_2, \ldots x_p$.

Будем в дальнейшем называть такие данные признаками (параметрами), а набор признаков $x_1, x_2, \ldots x_p$ – описанием больного.

Задача постановки диагноза состоит в следующем: по имеющемуся набору признаков, полученных у конкретного k–го больного $x_{k1}, x_{k2}, \ldots, x_{kp}$, необходимо поставить диагноз D_1 или D_2.

Множества признаков для диагнозов D_1 и D_2 могут быть пересекающимися и непересекающимися. В первом случае задача постановки диагноза сводится к построению разделяющей поверхности R (так называемого диагностического правила или дискриминантной функции). Тогда при предъявлении каждого нового

больного с целью постановки диагноза определяется, в какую часть пространства от поверхности R попадают значения признаков обследуемого больного. В рассматриваемом случае диагноз может быть поставлен однозначно: результат диагностики пациента D_1 или D_2.

Гораздо чаще встречается вторая ситуация, когда множества анализируемых признаков для диагнозов D_1 и D_2 являются пересекающимися. Это означает, что хотя бы один из признаков x_j , j =1…p, может принимать одно и то же значение для обоих диагнозов. В этом случае задача постановки диагноза также сводится к построению разделяющей поверхности R, но в, отличие от первого случая, диагноз D1 или D2 устанавливается с некоторой вероятностью.

Таким образом, задача диагностирования заболеваний математически может быть сведена к построению решающего правила (разделяющей поверхности R) и вычислению вероятности постановки правильного диагноза с помощью этого правила.

Рассмотрим задачу классификации изображений с точки зрения построения разделяющей поверхности.

Все размеры изображения являются характеристиками распознанного объекта. Если задать число элементов в n, размеры можно представить в виде вектора изображения:

$$x = (x_1, x_2 \dots x_n)^T \qquad (1)$$

Образы – это непрерывные функции. Если проводить измерения в дискретных точках, то вектор образа имеет вид:

$$x_1 = f(t_1),\ x_2 = f(t_2), \dots, x_n = f(t_n) \qquad (2)$$

Измерение значений функций в дискретных точках показано на рисунке 2.

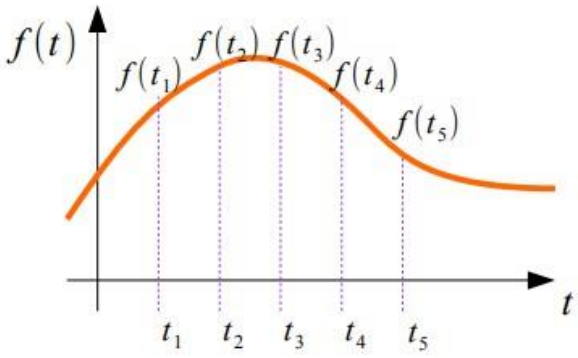

Рисунок 2 – Измерение значений функций в дискретных точках.

Если измерения приводят к информации в виде вещественных чисел, то векторы изображений рассматриваются как n-мерное Евклидово пространство [10, с. 34].

Изображения, принадлежащие к одному классу, рассматриваются как набор точек, лежащих в одной области. Тогда вектор изображения имеет вид:

$$x = (x_1, x_2)^T \qquad (3)$$

Демонстрация векторов образов в качестве точек n-мерного пространства показана на рисунке 3.

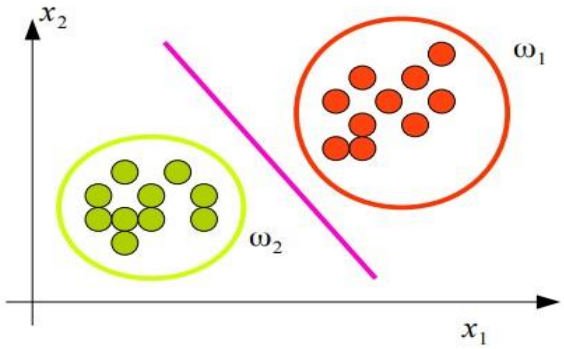

Рисунок 3 – Векторы образов в качестве точек n-мерного пространства.

Обработка исходных данных заключается в выделении характерных признаков и уменьшении размерности векторов изображения. Многие изображения одного и того же класса имеют особые отличительные черты. Такие признаки называются межгрупповыми. Набор образов, состоящий из образов всех классов, содержит внутриклассовые атрибуты. Эти функции не используются в задачах рас-

познавания изображений. Выбор признаков - сложная процедура, но она необходима для решения большинства практических задач автоматического распознавания.

Для классификации и идентификации необходимо, по мнению Барбары Бэйтс, Линна Бикли, Роберта Хекельман, найти решающие функции, которые построят границы области решения и разделят точки в размерном пространстве. Классифицируемые объекты должны иметь набор измеримых характеристик. Можно использовать различные методы для получения функций принятия решений.

Если априорная информация известна, то функции принятия решений определяются с использованием этой информации. Если известна только качественная информация, то границы области решения могут существенно отклоняться от реальных. Поэтому, согласно мнению Остапенко В.А., Привеса М.Г. и Стюарта Рассела, следует использовать дополнительную информацию, полученную с помощью лингвистической статистики, и корректировать функции принятия решений.

Точность распознавания зависит от количества разрешающей информации, содержащейся в характеристиках объекта. Для повышения точности распознавания необходимо измерить все возможные характеристики и увеличить время обработки [25, с. 44].

Выводы по разделу 2: Определение патологий на снимках представляет собой классификационную задачу. В рассматриваемом в работе случае задача классификации сводится к построению разделяющей поверхности.

3. ОБЗОР МЕТОДОВ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ

Среди основных методов определения класса можно выделить:

1. Определение класса по списку его членов.

2. Определение класса по свойствам, общим для всех его членов.

3. Определение класса путем формирования кластеров в пространстве объектов.

Если класс определяется списком его членов, алгоритм распознавания основан на сравнении объекта со ссылкой. Система хранит несколько объектов, принадлежащих к определенному классу. Когда в систему поступают новые объекты, она сравнивает их со стандартами.

Если объект соответствует ссылке, он принадлежит к соответствующему классу. Этот метод подходит для небольших систем с небольшим количеством элементов и особенностей.

Если класс определяется свойствами класса его членов, то алгоритм распознавания основан на выборе признаков. Объекты одного класса содержат общие свойства и атрибуты. Если в систему подается новый объект, то характеристики этого объекта сравниваются с характеристиками, хранящимися в памяти системы распознавания. При наличии необходимых атрибутов система присваивает объекту определенный класс.

В отличие от системы с определением перечня классов ее членов, принцип сравнения признаков допускает вариативность характеристик. Основная трудность этого метода заключается в нахождении полного набора признаков. Если класс определяется образованием кластеров в пространстве признаков, то классификация основана на принципе геометрической близости.

Объекты образуют область в пространстве объектов, называемую кластером. В таких системах, по мнению Привеса М.Г., Shanmuganathan S. и Xiao X.A., класс определяется на основе расположения объекта относительно кластера. Если кла-

стеры расположены далеко друг от друга, то объекты могут быть отнесены к классу, расстояние между которыми минимально.

Метод опорных векторов

Является одной из наиболее популярных методологий обучения по прецедентам.

Представляет собой коллекцию алгоритмов, которые нужны для решения задач классификаций или регрессионного анализа. Опираясь на то, что объект, находящийся в многомерном пространстве, относится к одному из двух классов, метод опорных векторов строит гиперплоскость с мерностью на одну меньше, чем имеется в пространстве, чтобы все объекты оказались в одной из двух групп.

Например, если имеется N-мерное пространство, то гиперплоскость будет состоять из N-1 измерений. Кроме разделения точек данный метод создает гиперплоскость таким образом, чтобы она была максимально отдалена от ближайшей точки каждой группы.

Метод опорных векторов имеет множество настраиваемых параметров, однако регулирование осуществляется выбором типа функции ядра. В зависимости от того, как распределены классифицируемые объекты в пространстве, применяют метод опорных векторов с той или иной функцией ядра.

Функция ядра определяет, каким образом классы будут условно разделяться в пространстве: линией, окружностями, кривой или с применением предварительной обработки данных, например, дисперсионного анализа.

Иллюстрация метода показана на рисунке 4.

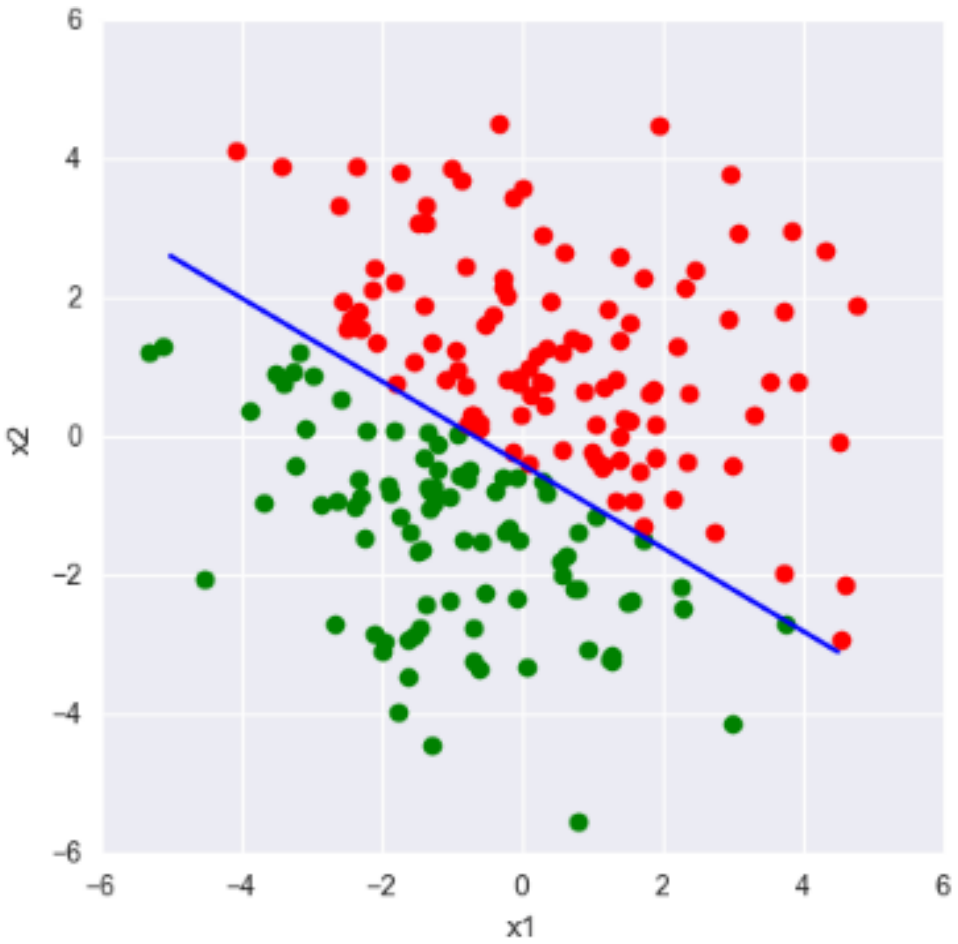

Рисунок 4 – Разделение пространства гиперплоскостью

В методе опорных векторов используется подход проецирования входного пространства в многомерное пространство, так что нелинейные данные также можно легко разделить. Цель метода состоит в том, чтобы выбрать оптимальную разделяющую гиперплоскость так, чтобы она максимально увеличивала расстояние между двумя точками данных из разных классов.

В методе опорных векторов для случая $m = 2$ решается задача, которая может быть представлена в следующем виде: найти

$$\eta^* = \min_{v, v_0} \left\{ \langle v, v \rangle + C \sum_{t \in T} \xi^t \right\}, \tag{4}$$

$$\left\langle v, x^t \right\rangle + v_0 \geq 1 - \xi^t, \ t \in T_1, \tag{5}$$

$$-\left\langle v, x^t \right\rangle - v_0 \geq 1 - \xi^t, \ t \in T_2, \tag{6}$$

$$\xi^t \geq 0, t \in T. \tag{7}$$

Метод опорных векторов используется для построения оптимального классификатора как для линейно разделимых классов, так и для линейно неразделимых классов.

Задача имеет вид:

$$\bar{q}^* = \frac{\delta}{B} \cdot \min_{v, v_0, \xi} \left\{ \sum_{t \in T} \xi^t \right\} \tag{8}$$

при ограничениях

$$\left\langle v, x^t \right\rangle + v_0 \geq 1 - \xi^t, \ t \in T_1, \tag{9}$$

$$-\left\langle v, x^t \right\rangle - v_0 \geq 1 - \xi^t, \ t \in T_2, \tag{10}$$

$$\langle v, v \rangle \leq 1/\delta^2, \tag{11}$$

$$\xi_t > 0, \ t \in T. \tag{12}$$

Рассмотрим некоторые недостатки данного метода.

1. Метод опорных векторов неустойчив по отношению к шуму в исходных данных. Если обучающая выборка содержат шумовые выбросы, они будут

существенным образом учтены при построении разделяющей гиперплоскости. Этого недостатка лишён метод релевантных векторов (relevance vector machine,)

2. До сих пор не разработаны общие методы построения спрямляющих пространств или ядер, наиболее подходящих для конкретной задачи. Построение адекватного ядра является искусством и, как правило, опирается на априорные знания о предметной области.

3. В общем случае, когда линейная разделимость не гарантируется, приходится подбирать управляющий параметр алгоритма C.

Алгоритмы кластеризации

Суть алгоритмов заключается в том, чтобы распределить коллекции объектов по кластерам таким образом, чтобы в каждом кластере оказались наиболее схожие элементы (рисунок 5) [23].

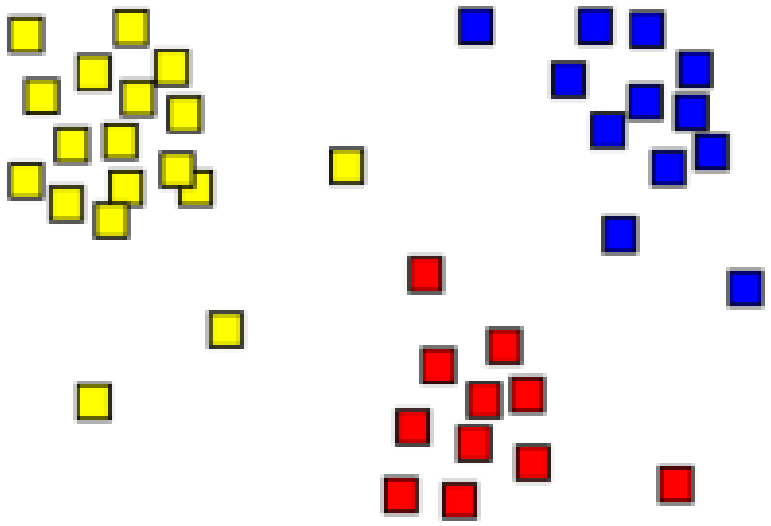

Рисунок 5 – Результат кластерного анализа обозначен раскрашиванием точек в соответствии с принадлежностью к одному из трёх кластеров

Существует несколько алгоритмов для кластеризации. При выборе алгоритма необходимо проанализировать его достоинства и недостатки, а также не исключать область данных, с которыми он наиболее совместим и способен масштабироваться.

Метод ансамблей

Данный метод основывается на алгоритмах машинного обучения, которые генерируют множество классификаторов и разделяют все объекты из вновь поступающих данных на основе их усреднения или итогов голосования.

Ансамбль представляет собой алгоритм обучения с учителем, по тем причинам, что его можно натренировать, а после использовать для осуществления предсказаний.

Тренированный ансамбль проверяет одну гипотезу. Однако она не должна находиться в пространстве гипотез моделей, из которых она состоит. В связи с этим, ансамбли имеют большую гибкость в функциях, которые они представляют.

Если сравнивать метод ансамблей с отдельными моделями прогнозирования, то он является более мощным методом, в связи с тем, что он сводит к минимуму воздействие случайностей, путем усреднения ошибок каждого базового классификатора, а также уменьшением дисперсии. Потому как несколько разных моделей, которые исходят из различных гипотез, имеют большую возможность приблизиться к верному результату, чем одна отдельно взятая гипотеза [14].

Метод главных компонент

Вычисление главных компонент сводится к вычислению собственных векторов и собственных значений ковариационной матрицы исходных данных или к сингулярному разложению матрицы данных.

Основные задачи, в которых применяется метод главных компонент – задачи адаптации, сокращения, уменьшение данных для облегчения процесса обучения.

Тем не менее, данный метод не подойдет в случаях, когда входные данные не упорядочены (то есть компоненты метода имеют высокую степень рассеивания), поэтому использование данного метода определяется степенью описания предметной области [12].

Нейронные сети

Основная идея искусственной нейронной сети берет свое начало из исследований принципов работы головного мозга. Сам термин появился при попытках создания математических моделей, которые бы смогли моделировать процессы, протекающие в нем.

Сегодня данная технология активно развивается и имеет большой спрос на рынке инфокоммуникационных технологий.

Прогнозирование, распознавание образов, анализ данных и принятие решений – основные задачи, которые способны решать нейронные сети. Применение искусственной нейронной сети дает массу преимуществ:

- Отказоустойчивость. Как и в человеческом мозге, повреждение нескольких нейронов не приводит значительному падению производительности. Качество снижение ее работы происходит медленно.

- Адаптация. Нейронные сети способны к переобучению при незначительных колебаниях окружающей среды.

- Решение задач с неизвестными закономерностями. В отличие от математических методов нейронная сеть способна решать задачи, которым сложно или невозможно в должной мере дать математическое или алгоритмическое описание.

- Быстродействие. За счет массового параллелизма обработки информации нейронные сети способны к сверхбыстрому быстродействию.

Искусственный нейрон – упрощенная модель нейрона мозга. Его основная функция – принятие входных данных (input), выполнение над ней простых вычислений и последующая передача результатов вычислений (output).

На основе того что нейрон делает с этими данными, выделяется три типа нейронов – входные, выходные и скрытные. Входной нейрон характерен тем, что он без изменений передает полученный им сигнал дальше по сети (input = output). Скрытые и выходные нейроны имеют своим параметром input суммарную output всех нейронов предыдущего слоя.

Полученная суммарная информация затем нормализуется при помощи функции активации и затем передается дальше по сети.

Основным параметром нейрона является так называемый bias (смещение) – любое число, влияющее на то, насколько легко активируется нейрон. То есть чем больше bias, тем вероятнее произойдет активация нейрона. Как и в человеческом мозге, результат работы определяется набором активированных нейронов. Функция активации – это выражение, преобразующее входные данные и bias в число, находящееся в диапазоне [0,1] или [-1,1].

В зависимости от значения, полученного в результате выполнения функции активации, нейрон считается либо активированным, либо не активированным. Результат функции активации - это и есть значение output нейрона.

Объединение множества нейронов (узлов), обрабатывающих сигнал от одного и того же источника, называется слоем. Все нейроны, принадлежащие одному слою, действуют вне зависимости друг от друга (параллельно).

Слои подразделяются на принимающие входной сигнал (входные), обрабатывающие информацию (скрытые), выдающие результат вычислений сети (выходные).

На рисунке 6 продемонстрирован пример нейронной сети с одним скрытым слоем.

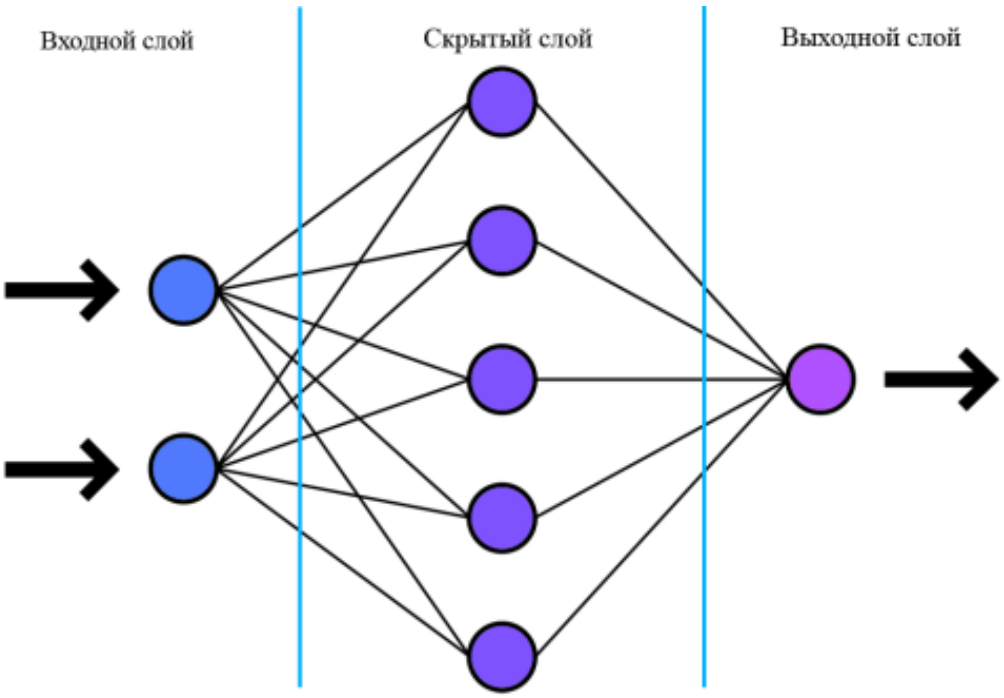

Рисунок 6 – Пример нейронной сети с одним скрытым слоем

Нейроны соседних слоев связаны друг с другом с помощью синапсов, передающих выходные данные одного нейрона на вход другого.

У каждого синапса есть единственный параметр – целое или рациональное число, которое называется весом.

Вес синапса дает понять, как сильно активация одного нейрона повлияет на активацию другого.

Для того чтобы в результате своей работы нейронная сеть дала полезный результат её подвергают тренировке. Тренировка или обучение нейронной сети заключается в подборе значений параметров нейронов и синапсов.

Существует несколько методов обучения:

- Обучение с учителем или контролируемое обучение (supervised learning). Данный метод применятся для проблем классификации данных. При таком подходе к обучению на вход нейронной сети предоставляется набор индексированных тренировочных данных.

Сеть в течение многих циклов оттачивает значения параметров нейронов и синапсов, сравнивая результат своей работы с индексированными данными. В результате должна получиться сеть, способная с малой долей ошибки индексировать данные, отличающиеся от тестовых.

- Обучение без учителя или неконтролируемое обучение (unsupervised learning). Данный метод применяется в тех случаях, когда нет возможности проиндексировать входные данные.

- Обучение с вознаграждением (reinforcement learning). Сущность этого метода заключается в том, что на вход нейронной сети не предоставляются статические данные. Сеть взаимодействует с окружающей средой, ограниченной контекстом задачи, и пытается максимизировать какое-либо значение, то есть получить награду. Такой метод применяется в задачах, например, в задачах связанных с взаимодействием роботов с предметами физического мира.

Предварительно обученные нейронные сети можно использовать для решения не только тех задач, на которых они обучались, но и для задач схожей природы, при помощи технологии дообучения.

Для этого от предварительно обученной сети «отрезается» классификатор (полносвязные слои) и вместо него добавляется новый, приспособленный для новой задачи.

Существует два способа дообучения: с перекомпиляцией и без нее [15]. Как правило, при дообучении не компилируют повторно. Несколько слоёв нейронов размораживают и добавляют классификатор. После этого сеть компилируется и обучается.

Другой способ использования предобученных сетей — дообучение с перекомпиляцией. Его основная идея заключается в том, что сначала обучается классификатор, а потом, после перекомпиляции, обучаются размороженные блоки.

Именно метод нейронных сетей является на сегодняшний момент одним из самых популярных в классификации медицинских и иных изображений во

многом благодаря своей эффективности. Он применим для данных различного формата, в том числе для рассмотренных наборов данных формата DICOM и PNG.

Единственным явным недостатком метода применительно к контексту медицинской сферы может оказаться его низкая интерпретируемость. Иными словами, в медицинской среде метод может вызвать низкий уровень доверия. Однако данная проблема легко решается в случае, если мы используем компьютерную классификацию изображений в качестве вспомогательного инструмента для «второго чтения» рентгеновских изображений, оставляя принятие решения за экспертом – врачом-рентгенологом.

Выводы по разделу 3: для классификации изображений применяют различные математические методы. Самым эффективным и распространенным из них являются нейронные сети. Применение нейросетей потребует подготовить большое количество данных.

4. ОБЗОР ПУБЛИКАЦИЙ И ТЕХНОЛОГИЧЕСКИХ РЕШЕНИЙ

Обзор существующих программных решений для классификации медицинских изображений

Системы поддержки принятия врачебных решений (СППВР) и продукты на базе искусственного интеллекта (ИИ), вероятно, станут наравне с телемедициной и электронными медицинскими картами (ЭМК) основой в развитии цифрового здравоохранения. Отечественные решения и команды, которые работают по этой теме, уже сейчас предлагаю продукты и сервисы.

В ходе анализа рынка программных продуктов удалось выявить 17 отечественных систем для диагностики заболеваний. Они представлены в таблице 1.

Таблица 1 – Отечественные программные продукты на основе методов ИИ для диагностики заболеваний.

Описание решения	Сайт
«Botkin.ai» – система предназначена для автоматического выявления патологических проявлений в рентгенологических исследованиях, КТ и МРТ, а также маммограмм	http://botkin.ai
«Третье мнение». Компания в сотрудничестве с онкологическими клиниками развивает интерфейс по распознаванию типов клеток крови, а также разрабатывает софт для анализа медицинских изображений рентгенографии легких, маммографии, компьютерной томографии и УЗИ	https://3opinion.ru/
«UNIM» – компания, являющаяся разработчиком программной платформы для патоморфологической диагностики и одновременно является крупным диагностическим оператором (около 4000 пациентов в месяц). Технологии представляют собой end2end решение для организации работы лаборатории в цифровом формате. Включают в себя системы поддержки принятия врачебных решений на базе искусственного интеллекта.	https://unim.su/
«CoBrain-Аналитика» - платформа для сбора, хранения, анализа и обработки больших медицинских данных о головном мозге человека в разных состояниях. Помогает ставить диагнозы, формировать персональную терапию для пациентов с заболеваниями	https://cobrain.io/

мозга, выявить патологию, которая физически еще не проявилась	
«Доктор Томо» - интеллектуальная технология ранней диагностики онкопатологий легких на базе данных компьютерной томографии	http://doctor-tomo.ru/
«Анализ флюорограм» - сервис умеет анализировать цифровые флюорографические снимки и выявлять в них патологические очаги	http://www.ftizisbiomed.ru/
«Skychain Global» - платформа для создания решений на базе ИИ для медицины, включая анализ изображений и выявление патологий	http://ru.skychain.global/
«Автоплан» - помогает анализировать медицинские изображения и формировать протоколы обследования	http://autoplan.clinic/
«Care Mentor AI» - система искусственного интеллекта для интерпретации результатов лучевых исследований (рентгенологических, КТ, МРТ и маммографии) с целью оптимизации обнаружения различных патологических состояний на ранней стадии	http://carementor.ru/
«Diagnocat» - система распознаёт томографические стоматологические исследования, помогает поставить диагноз и даёт врачам рекомендации по лечению	https://diagnocat.com/
Решения семейства xGen. Включают продукты для помощи в диагностике ряда заболеваний	http://www.xgen.ru/soft.htm
«CVisionLab». Разрабатывают наукоёмкое ПО в области компьютерного зрения и машинного обучения, в том числе анализ и распознавание медицинских изображений.	https://www.cvisionlab.com/
«Doctor AIzimov». Анализирует снимки компьютерной томографии на предмет онкологической патологии	
«ФтизисБиоМед» Флюорограммы анализируются на наличие всех возможных патологий, которые можно выявить при флюорографии	http://ftizisbiomed.ru/
«Celsus». Развивают нейросети, которые позволяют выявлять патологические очаги в рентгенографии и компьютерной томографии	https://celsus.ai/
«Anna Project». Создают ряд сервисов для работы с цифровыми изображениями, включая применение ИИ для поиска патологий и автоматизированного заполнения протоколов	http://mri-ai.com/
«Skinive» позволяет выявлять подозрения на кожные заболевания	https://www.skinive.com/

и проводить самоконтроль между осмотрами у дерматологов для пациентов предрасположенных к онкологии кожного покрова, вирусных, грибковых и бактериальных заболеваний	

Получив демо доступ к программам ФтизисБиоМед и Botkin.ai, проанализируем эффективность на флюорографических снимках ГБУЗ «ЧОКПТД».

Эксперименты были проведены на 1000 флюорографических снимках, в двух системах были получены результаты, представленные в таблице 2. Точность показывает, в скольких случаях программа правильно классифицировала снимок на «норма» или «патология».

Таблица 2 - Точность работы программных продуктов

Наименование	Точность определения патологии,%
Botkin AI	43
ФтизисБоиМед	40

Точность анализа снимков недостаточна для использования их в работе рентгенологической службы. Приведенные программные продукты требуют доработки.

Анализ публикаций по теме классификации медицинских изображений

Анализ отечественных и зарубежных публикаций по теме работы показал, что одним из ключевых этапов машинного обучения является этап предварительной обработки данных. В зависимости от специфики изучаемой области и преследуемых целей выбираются определенные методы.

В работах авторов Хамад Ю. А., S. Candemir, Chen M. приводятся методы предварительной обработки, такие как локальное улучшение контраста и сегментация легких.

Методы усиления контрастности используются для повышения контрастности изображения. Одним из важных факторов, влияющих на качество изображе-

ния, является уровень контрастности изображения. Если контраст слишком низкий или слишком высокий, то изображение не подойдет для обучения. Этот метод применяется в случае, если приходится работать с изображениями низкого качества.

Сегментация легких – это метод предварительной обработки, который состоит в том, чтобы распознать и затем отделить область легких от сердца и других органов.

Метод сегментации легких включает следующие этапы:

1. Поиск границ легких путем обучения сверточной нейронной сети для сегментации легких по исходной строке данных с вручную подготовленными «масками» (lung boundaries).

2. Определение границ легких как черно - белых «масок» с использованием сверточной нейронной сети для каждого исходного изображения из набора данных.

Рисунок 7 - Пример работы метода сегментации легких.

Доказано, что метод сегментации легких позволяет улучшить качество классификации изображений. Но на наш взгляд, этот метод имеет ряд недостатков, ограничивающих возможность его применение.

1. «Маски» легких должны быть подготовлены в ручную. Это занимает значительное время, требует привлечения специалистов по рентгенологии. Подготовленные «маски» могут не подходить для снимков разных размеров, могут не учитывать физиологические отклонения пациентов (например, есть пациенты с одним легким).

2. Выделяются только области легких без окружающих тканей. Анализируя только легочную ткань, легко пропустить окружающие патологии, например патологии сердца.

В связи с перечисленными недостатками этого метода, имеет смысл построить предварительную обработку изображений так, чтобы она была автоматической (не требовала ручного труда эксперта) и сохраняла на изображении ткани легких, сердца, окружающих областей.

Таким методом может стать «удаление реберных костей» с изображения. По опросам экспертов врачей-рентгенологов ГБУЗ «ЧОКПТД» реберные кости закрывают ткани легких, ухудшая просмотр изображения. При этом реберные кости не участвуют в определении патологии на изображении.

Дальнейший анализ литературы показал, что фильтрации костной ткани уделялось не так много внимания, хотя можно предположить, что применение этого метода имеет большое значение в клинической практике и полезно при диагностике заболеваний легких.

Наибольшие трудности при фильтрации костной ткани вызывает этап определения разницы в интенсивности текстуры костной и легочной ткани. Этот шаг необходим для немедленного удаления силуэтов костей путем уменьшения разницы между интенсивностями до минимума. Лучший алгоритм, который справляется с этой задачей приведен в работах Кириловой С. и Курако М. Принято решение использовать алгоритм для удаления костной ткани. Более подробно он описан в разделе 6.

Выводы по разделу 4: рассмотренные отечественные программные продукты не подходят для решения задачи классификации изображений на данных флюорографических снимков ГБУЗ «ЧОКПТД». Требуется разработка методик повышения качества классификации медицинских изображений.

Самыми распространёнными методами повышения качества классификации медицинских изображений являются метод усиления контрастности и метод

сегментации легких. В связи с недостатками этих методов принято решения воспользоваться методом «удаления костной ткани» для ребер на изображениях.

5. ПОДГОТОВКА ДАННЫХ ДЛЯ ЭКСПЕРЕМЕНТОВ

Наличие качественного источника размеченных медицинских данных – ключевое условие успешного создания решений в области искусственного интеллекта для медицины. Существует ряд хранилищ (data set), содержащих рентгеновские снимки [36]. Считается, что снимки в данных хранилищах уже являются подготовленными для работы по классификации. Далее определим так ли это на самом деле, и какие открытые наборы данных пригодны для проведения экспериментов по классификации изображений.

Набор цифровых снимков грудной клетки (NIH Chest X-ray Dataset of 14 Common Thorax Disease Categories). Набор данных содержит 112 тыс. изображений 30 тыс. уникальных пациентов с фронтальным обзором и примерами 14 торакальных патологий.

Доступ:

http://academictorrents.com/details/557481faacd824c83fbf57dcf7b6da9383b3235a

Белорусский туберкулезный портал (Belarus tuberculosis portal). Туберкулез является серьезной проблемой системы здравоохранения Беларуси. Многие тяжелые формы распространены по всей стране и наблюдаются в различных противотуберкулезных диспансерах. Ожидается, что способность ведущих белорусских специалистов по туберкулезу следить за такими пациентами может быть значительно улучшена за счет использования общей базы данных, содержащей радиологические изображения пациентов, лабораторные работы и клинические данные. Это также значительно улучшит соблюдение стандартов лечения и приведет к лучшим результатам лечения. В наборе данных есть рентгенографии грудной клетки и компьютерная томография одного и того же пациента.

Доступ: http://tuberculosis.by/

База данных «Сегментация в рентгенограммах грудной клетки» (Segmentation in Chest Radiographs – SCR). Автоматическая сегментация

анатомических структур в рентгенограммах грудной клетки имеет большое значение для компьютерной диагностики. База данных SCR была создана для облегчения сравнительных исследований по сегментации легочных полей, сердца и ключиц в стандартных рентгенограммах грудной клетки.

Доступ: http://www.isi.uu.nl/Research/Databases/SCR/

Сводная информация о некоторых наборах данных, содержащих рентгеновские изображения легких, приведена в таблице 3.

Таблица 3 - Сводная информация о наборах данных

Название	Без патологии	С патологией	Общее количество	Формат	Разрешение
Montgomery Country chest X-ray dataset	80	58	138	DICOM	4020x4892
Belarus tuberculosis database	-	464	464	DICOM	2248x2248
NIH Chest X-rays dataset	63170	48950	112120	PNG	1024x1024
JSRT database	93	154	247	PNG	2048x2048
Shenzhen Hospital X-ray Set	326	336	662	JPEG	N/A

Из таблицы мы видим, что существует проблема низкого числа снимков в наборах данных. Их может быть недостаточно для построения модели. В этом плане единственным пригодным набором данных для решения задачи классификации может оказаться NIH Chest X-rays dataset, который содержит более 100 тысяч снимков.

Набор данных медицинского учреждения

Для понимания, достаточно ли снимков содержится в хранилищах медицинских изображений государственных и частных медицинских учреждений, рассчитаем объем снимков на примере Государственного бюджетного учреждения здравоохранения «Челябинского областного клинического противотуберкулезного диспансера».

Для простоты рассмотрим только флюорографические аппараты. В учреждении имеется 5 цифровых флюорографических аппаратов стационарного типа (расположенных в здании) и 4 передвижных (установленных в машинах). В среднем в день, каждый комплекс может производить от 10 до 70 снимков. Это порядка 8000 снимков в месяц и 95 000 в год.

Архивы медицинских изображений хранятся не менее 25 лет. Но возраст аппаратов составляет 5-10 лет. На основании этого мы можем утверждать, что данных флюорографических снимков даже одного медицинского учреждения будет достаточно для проведения экспериментов по классификации флюорографических изображений. Кроме того, стандарт хранения этих изображений DICOM позволяет считать их пригодными для проведения анализа и обработки.

Стандарт DICOM разработан Американским колледжем радиологии (ACR) и Национальной ассоциацией производителей электрооборудования (NEMA). Со стандартом можно ознакомиться на официальном сайте NEMA: http://medical.nema.org/dicom

Таким образом, DICOM поддерживает:

- большинство систем PACS (Picture Archiving and Communications);
- инфраструктуру хранения данных;
- инфраструктуру получения изображений;
- инфраструктуру визуализации и печати изображений.

Набор данных формата DICOM является стандартизированным множеством, при этом все одиночные изображения находятся на одном уровне файловой системы в хаотичном порядке. Определенный порядок в файлы изображений вносят метаданные, которые сохраняются в одном файле DICOMDIR. Файл DICOMDIR формирует файлы изображений по иерархической структуре (рисунок 8).

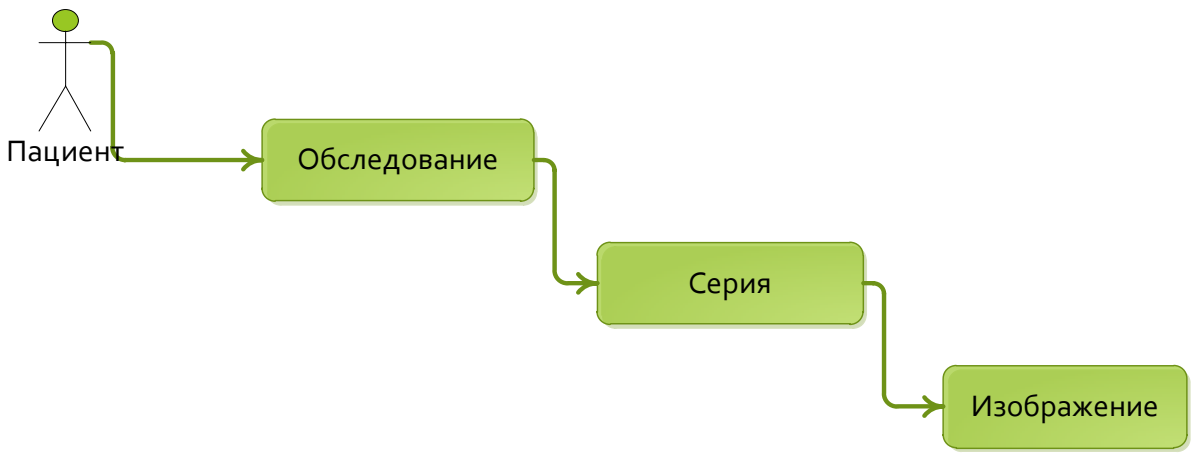

Рисунок 8 – Иерархическая структура формирования файлов изображений

Знание об обширном наборе тегов формата DICOM необходимо для понимания какую дополнительную информацию можно извлечь из файлов для повышения качества классификации снимков. Так, снимки могут содержать информацию о поле, возрасте пациента, текстовое описание патологии, а также содержать технические данные о типе оборудования, на котором был выполнен снимок и дозе радиации. Пример описания тегов DICOM приведен в приложении А. Из приложения видно, что описание снимков для классификации как правило содержится в тегах (0008,1030).

Подготовка данных

Самым первым шагом был анализ содержания изображений. Оказалось, что многие изображения не подходят для обучения нейронной сети на них. Поэтому было решено удалить некачественные изображения. Изображение считалось некачественным в следующих случаях:

1. Изображение было сделано не в прямой проекции.
2. Положение груди на изображении слишком искажено.
3. Изображение содержит много посторонних предметов в области грудной клетки, таких как провода от медицинских приборов, булавки, кнопки, кардиостимуляторы и так далее.

4. Изображение слишком размыто или подсвечено

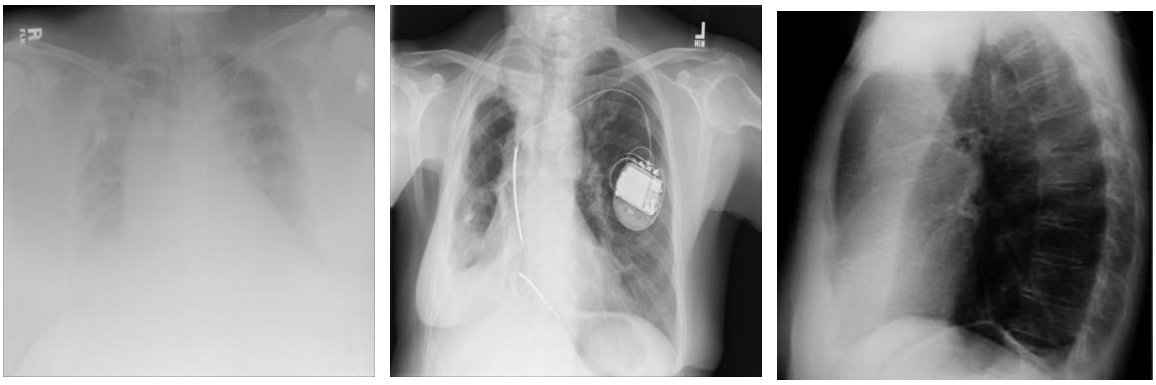

Рисунок 9 - Примеры некачественных снимков.

Далее для осуществления компьютерной классификации рентгеновских изображений легких по признаку «результат диагностики» («норма» и «патология») необходимо провести предварительную обработку имеющейся базы изображений.

Рентгеновские снимки хранятся и передаются в специализированном отраслевом формате DICOM, который является стандартом для хранения и распространения медицинских снимков. Он включает в себя одно или несколько изображений, информацию о пациенте, результатах проведенного обследования, данные организации, проводившей диагностику и даже информацию о приборе, с помощью которого проводилось обследование.

Для хранения данных об изображениях создана база данных (БД) в СУБД MS Access. В данной БД хранится информация о диагнозе, графическое изображение снимка и данные из файла DICOM, сохраненного в текстовом формате. Визуальная информация получена из файла формата DICOM путем его конвертирования в формат jpeg с применением on-line конвертора [13]. Структура таблицы с отображением полей и их типов, представлена на рисунке 10.

Fluorography

Имя поля	Тип данных
ID	Счетчик
Diagnosis	Текстовый
View	Поле объекта OLE
Files	Поле MEMO

Рисунок 10 – Таблица «Fluorography» базы данных

С целью выделения нужной информации о результате диагностики из файла DICOM, сохраненного в текстовом формате, была разработана прикладная программа «Обработка изображений» в среде программирования Delphi 7. Интерфейс программы приведен на рисунке 11.

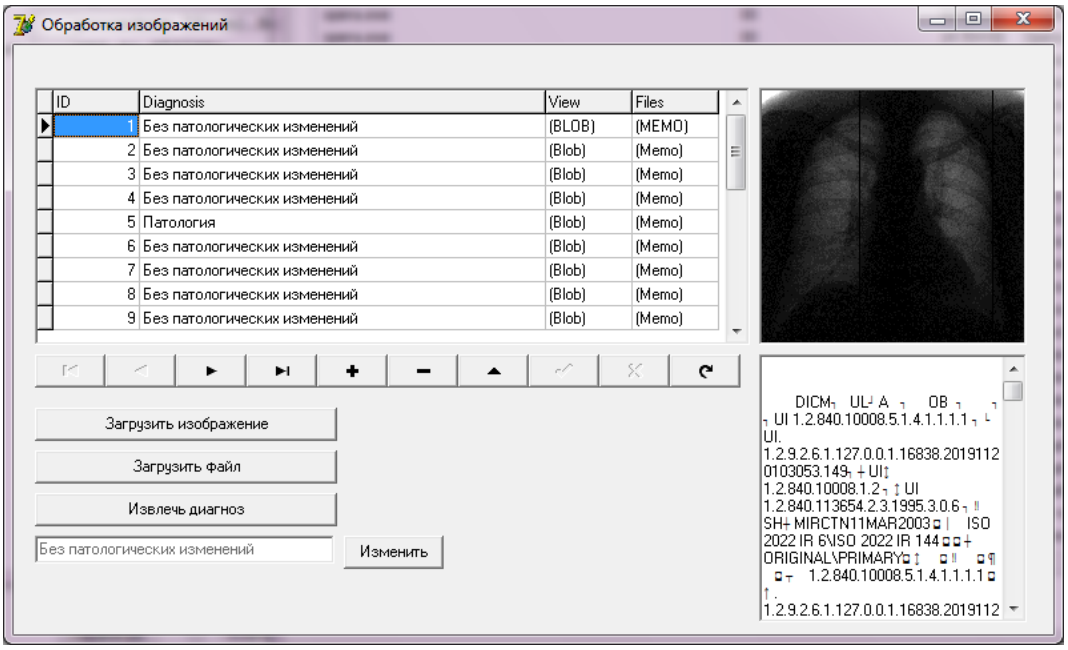

Рисунок 11 – Интерфейс программы «Обработка изображений»

Данная программа позволяет просматривать, добавлять, удалять и редактировать информацию о флюорографических снимках. Все изменения с данными, осуществленные в программе, соответственно меняют данные в БД. Программа имеет диалоговый интерфейс. При нажатии на кнопку «Загрузить изображение», открывается диалог загрузки изображений (рисунок 12).

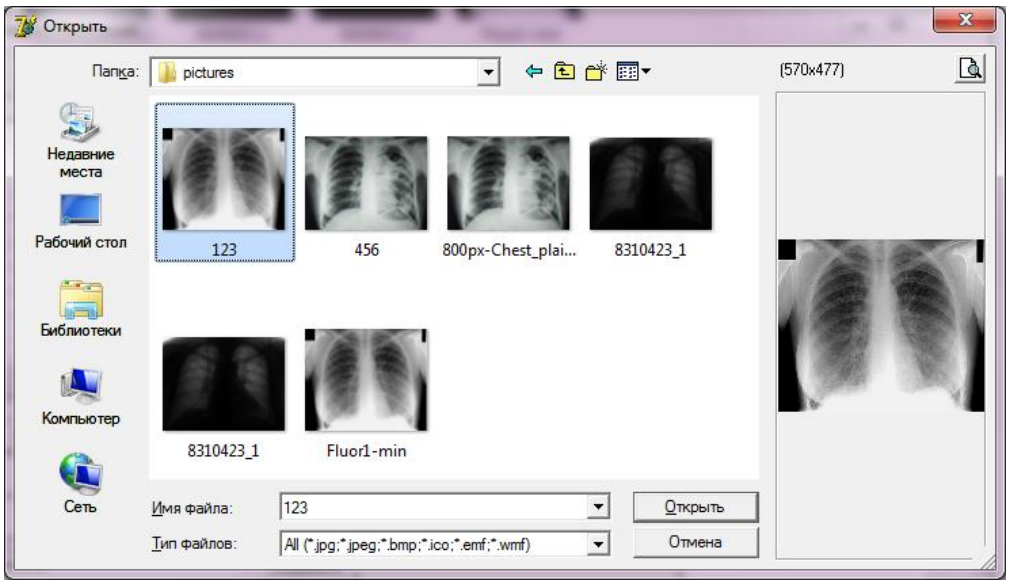

Рисунок 12 – Диалог загрузки изображения

Загрузка DICOM-файла, сохраненного в текстовом формате, осуществляется по аналогичному алгоритму по нажатию кнопки «Загрузить файл»

После того, как вся необходимая информация загружена, пользователь имеет возможность провести компьютерный поиск диагноза по данным из файла DICOM, сохраненного в текстовом формате. Для этого необходимо нажать на кнопку «Извлечь диагноз». При этом по умолчанию ищется диагноз «Без патологических изменений». Программа позволяет изменить искомый диагноз в поле для ввода текста. По умолчанию поле не активно. Чтобы внести изменения необходимо нажать на кнопку «Изменить». В этом случае поле ввода текста станет активным, а кнопка поменяет название на «Сохранить» (рисунок 13).

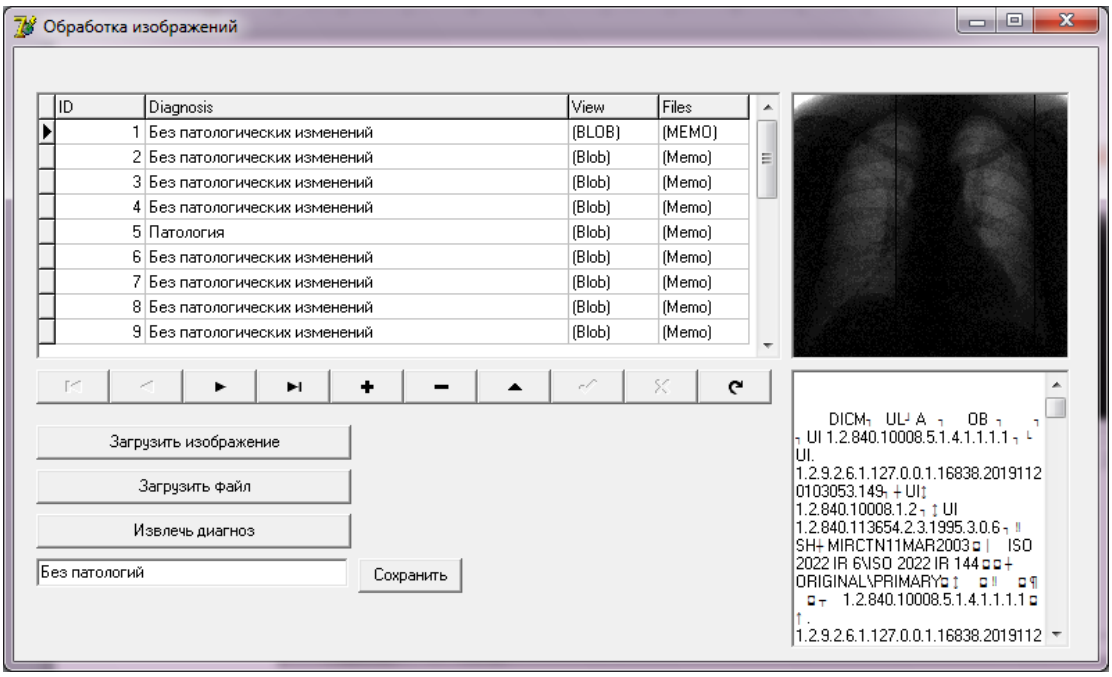

Рисунок 13 – Изменение критерия поиска

Если искомый диагноз обнаружен в тексте, то в таблицу базы данных заносится строка «Без патологических изменений» или любая другая искомая строка, введенная в текстовое поле. Если программа провела обработку всего файла, относящегося к выделенной записи, и не обнаружила требуемую запись, то в поле «Diagnosis» данной записи заносится строка «Патология». Код программы на языке Delphi 7 приведен в приложении Б.

Выводы по 5 разделу: для проведения экспериментов среди открытых наборов данных был выбран NIH Chest X-rays dataset . Ключевым критерием выбора стало количество снимков, содержащееся в наборе, поскольку одной из особенностей методов глубокого обучения является потребность большом количестве исходных данных

Проведена предварительная обработка данных: из наборов снимков удалены некачественные изображения, проведена классификация ФОГ снимков ГБУЗ «ЧОКПТД», для этого была разработана программа «Обработка изображений».

Программа позволяет вести базу снимков, детектировать наличие или отсутствие искомого диагноза в файле DICOM, сохраненном в текстовом формате, и для каждого снимка хранить в отдельном поле информацию о диагнозе на снимке.

Данная предварительная обработка позволит подготовить обучающий набор данных для обучения нейронной сети.

6. УДАЛЕНИЕ КОСТНОЙ ТКАНИ С ИЗОБРАЖЕНИЯ

На основе опроса экспертов (враче рентгенологической службы) удалось определить, что при просмотре снимка наибольшее затруднение вызывают объекты, затененные костной тканью. В связи с большей плотностью костной ткани на снимках она отображается на переднем фоне, затрудняя просмотр тканей легких за ней.

Одним из таких объектов является тень от ребер (рисунок 14).

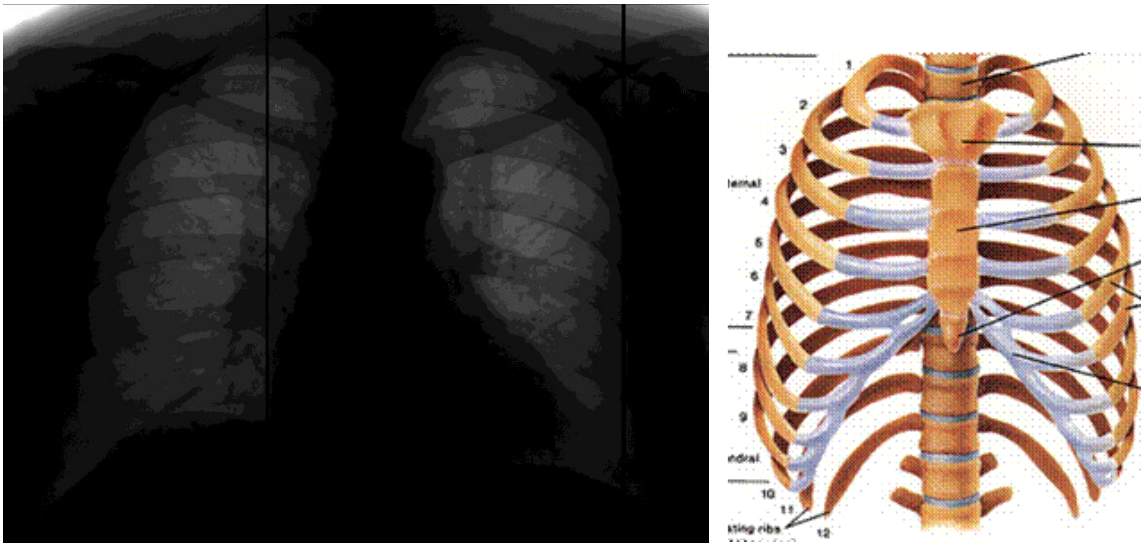

Рисунок 14 – Строение ребер

Основываясь на имеющихся экспериментальных данных, определим вид кривой, аппроксимирующей кривую ребра. Для построения модели сформируем таблицу экспериментальных данных, полученных на основе оцифровки реальных изображений.

На рисунке 15 представлены выражения, описывающие экспериментальные кривые. Для моделирования границ ребер данного вида подходящими являются полиномиальные модели второго порядка.

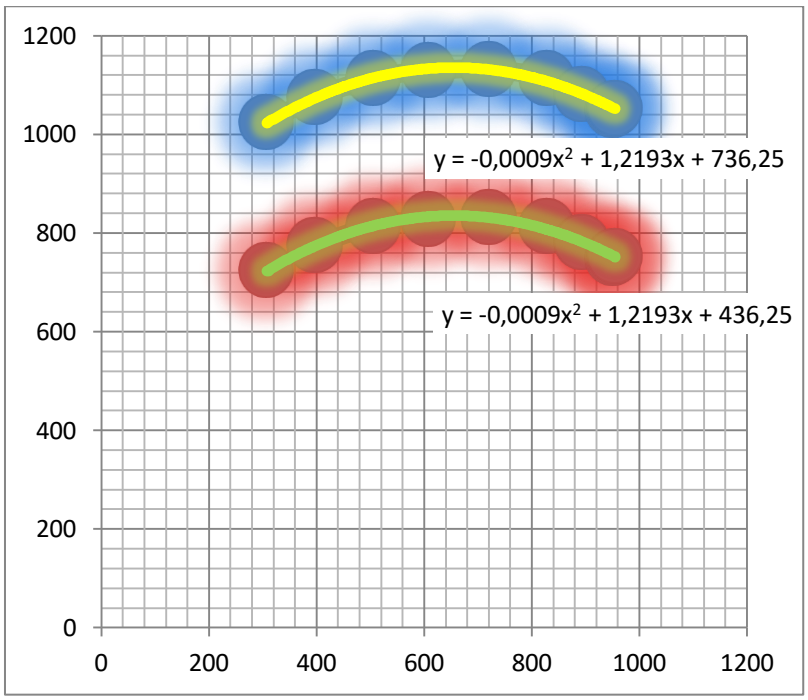

Рисунок 15 – Экспериментальные и аппроксимирующие кривые

Для удаления ребер с изображения рассмотрим метод, при котором шаг разграничения ребер пытается подогнать шаблон параболической кривой от начального значения начальной точки ребра. В этом случае можно определить кривую в середине ребра, а не на границах ребра.

Весь контур ребра очерчивается при помощи метода выращивания проблемной области. Эта метод позволяет системе обнаруживать точные области ребер, которые не обязательно следуют глобально подобранному уравнению параболы, извлеченному из лучшего шаблона.

Определение ребер включает шесть этапов:

1) извлечение шаблона;

2) обнаружение ребра начинается в самой верхней области грудной клетки путем фильтрации Габора;

3) выбор единственного лучшего шаблона, который наиболее совместим с грудной клеткой;

4) оценка толщины ребра;

5) параболическая установка для обнаружения всех ребер;

6) разграничение всего набора ребер с помощью определенной техники выращивания области.

Когда для каждой части легкого оценивается более одного шаблона, их необходимо уменьшать, вычисляя их расстояние до каждой из утонченных реберных структур. Ближайший шаблон выбирается как лучший. Когда шаблон найден только для одного легкого (справа или слева), создаем новый шаблон, беря симметрию существующего. Расчет симметрии шаблона состоит из трех этапов.

1) Лучший шаблон должен быть сформирован в виде эллиптической кривой, поскольку он состоит из рассеянных пикселей (рисунок 16, темно-синие линии на правом легком). Используя эти неотформированные пиксели, находятся коэффициенты для полинома p(x) степени n, который лучше всего подходит (в смысле наименьших квадратов) для данных по y.

$$p(x) = p_1x^n + p_2x^{n-1} + \cdot \cdot \cdot + p_nx + p_{n+1} \tag{13}$$

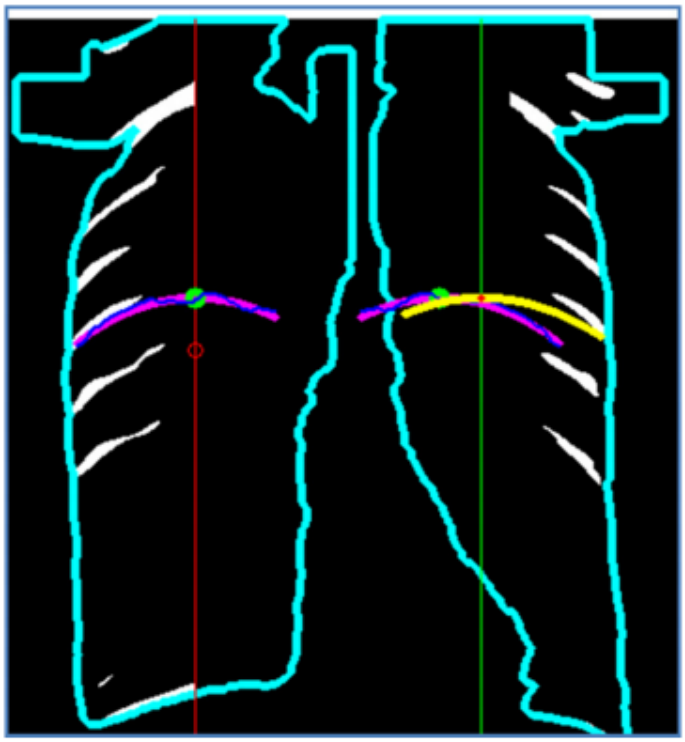

Рисунок 16 – Выбор лучшего шаблона на основе обнаруженного края ребра

2) Рассчитывается его зеркальная симметрия (рисунок 16, пурпурные линии).

3) Его окончательное положение находится относительно центра масс области (рисунок 16, желтая линия). После того, как координаты x и y вершины параболы вычислены, определяется разница между этой точкой и центром массы, составляющей поле легкого, на котором лежит этот шаблон. Поскольку это расстояние должно быть одинаковым в этих симметричных полях легких, смещение симметричного шаблона приводит к получению окончательного шаблона для левого легкого.

Значение высоты ребра (rh) используется в качестве критерия остановки при увеличении ширины ребра от его центра. Основная задача вычисления rh – найти самую длинную вертикальную линию, которая существует на реберных структурах. Используя все вертикальные линии - кроме тех, которые являются слишком тонкими (24 пикселя), была высчитана средняя высота ребра. Поскольку самые верхние области ребер легче обнаружить, оценка высоты ребра на этом этапе делает возможным дальнейшее разграничение.

Подгонка параболы – это задача оценки параметров шаблонного уравнения параболы, которое описывает приблизительный центр всех ребер, у которых обнаружены их внешние границы. Чтобы соответствовать кривой в средней части ребра, необходимо оптимизировать последний параметр параболы.

В то время, как первый и второй параметры связаны с формой, третий параметр влияет на положение шаблона на ребре, перемещая шаблон вверх и вниз. Сохраняя первые два параметра одинаковыми, проведен расчет значений p3 для каждого ребра, используя каждую пару пикселей, которая появляется в структуре. Данный алгоритм приводит к формированию окончательного шаблона для соответствующего ребра.

Каждое ребро в грудной клетке потенциально имеет различную геометрию в зависимости от его расположения по вертикали. Следовательно, глобальная

шаблонная парабола, расположенная в определенном ребре, начиная с самого его края, не обязательно вписывается в его структуру кривизны.

Для решения этой проблемы предлагается уточнение центра ребра путем повторной оценки параметров уравнения параболы, характерных для ребра, и линейного удлинения ребра до достижения прогнозируемой высоты ребра. Метод выращивания ребер обрабатывает каждый пиксель в первой параболической кривой независимо и сдвигает его вертикально в новую позицию.

Это положение определяется таким образом, что оно максимизирует разницу интенсивности верхней половины ребра с тканью легкого над его границей и нижней половины ребра с тканью легкого под его границей (рисунок 17).

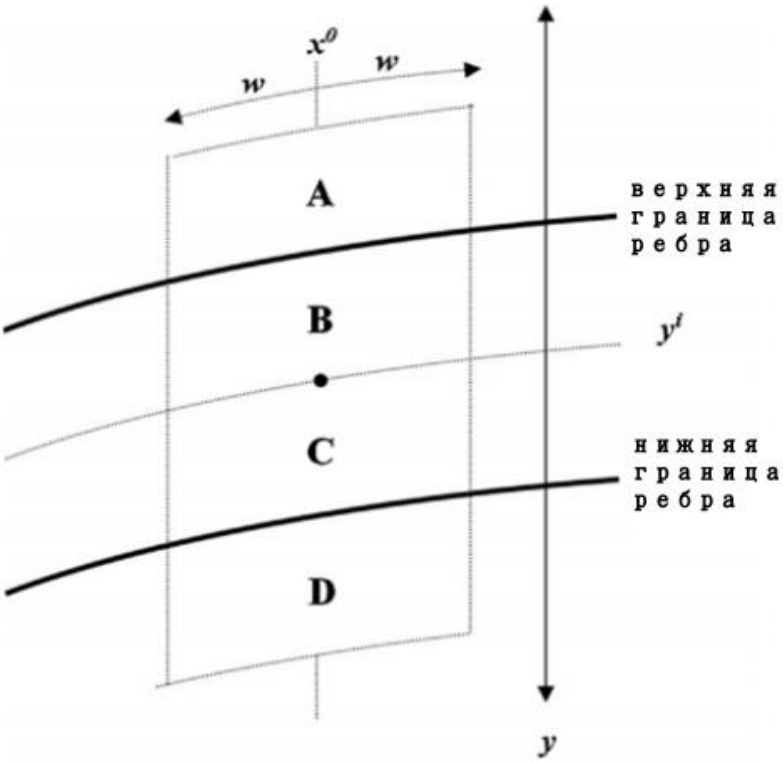

Рисунок 17 – Поиск центра ребра

Новое положение этого пикселя, скорее всего, будет в вертикальном центре ребра, поскольку все ребро часто имеет более высокую интенсивность, чем легочная ткань выше и ниже границ ребра. Для фиксированного горизонтального положения x^0 вертикальное положение центра ребра y^0 сдвигается в новое положе-

ние y^i, где i относится к числу сдвигов пикселей в любом направлении, то есть вверх или вниз.

Значение i определяется путем исчерпывающего поиска между -rh/2 < i < rh/2, чтобы максимизировать следующую целевую функцию:

$$f(i) = \frac{\sum_{y^i<y<y^i+rh/2} L_\omega(x,y)}{\sum_{y^i+rh/2+1<y<y^i+rh} L_\omega(x,y)} + \frac{\sum_{y^i-rh/2<y<y^i} L_\omega(x,y)}{\sum_{y^i-rh/2-1<y<y^i-rh} L_\omega(x,y)} \quad (14)$$

для вертикальной позиции y, а ω –параметр, который обозначает ширину области, рассматриваемой для сравнения интенсивностей между областями. Значение ω должно быть достаточно большим, чтобы появление аномалии в этой области не нарушало границы ребер, и должно быть достаточно маленьким, чтобы изменения общей интенсивности пикселей в горизонтальном направлении не влияли на локальную модель интенсивности ребер. Операция сдвига разрешена не более, чем в два раза выше в обоих направлениях, поскольку при дальнейшем сдвиге пиксель может совпадать с границей другого ребра. Из-за неравномерностей в ткани легких предполагаемые центральные пиксели могут быть перемещены в неправильном направлении. Следовательно, отдельная парабола может быть вставлена в каждое ребро в одной и той же грудной клетке, руководствуясь исходным глобальным шаблоном. Принимая новую параболическую кривую в качестве полного центра ребра, задача увеличения области ребра для окончательного разграничения сводится к расширению центральной кривой в верхнем и нижнем направлениях в течение rh/2 раза.

После определения ребер на изображении следующим шагом является подавление выделенных областей для удаления тени ребер без потери информации об исходной ткани легкого. Принято допущение, что вертикальный центр ребра имеет наибольшую толщину в проксимальном направлении, а границы имеют самую низкую. Следовательно, подавление начинается с пикселей в вертикальном центре ребра и продолжается адаптивно, пока не будут достигнуты границы ребра.

В качестве примера обработки приведен рисунок 18.

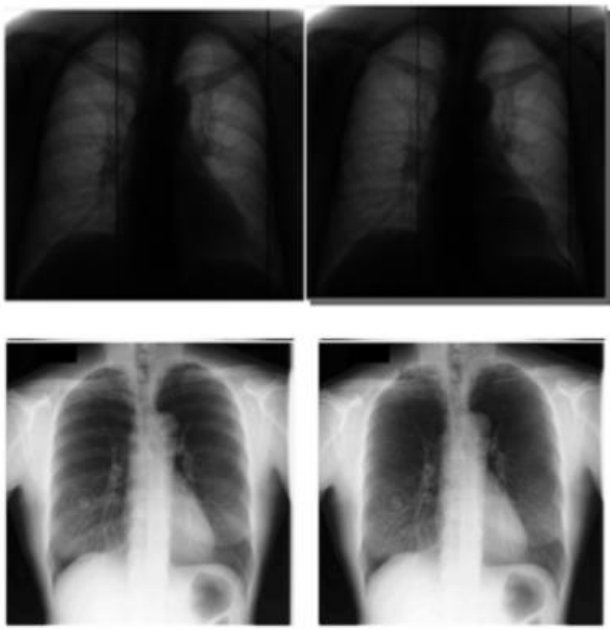

Рисунок 18 – Снимок до обработки (слева),
снимок после исключения ребер (справа)

Выводы по разделу 6: одной из помех для более качественной диагностики, является наличие шумов в виде тени от ребер. В данном разделе описана эта проблема и приведен алгоритм идентификации контуров ребер на изображении на основании базы шаблонов полиномиальных кривых. Фактически задача удаления реберной ткани с изображения сводится к определению контуров всех ребер, определению структуры легочной ткани в непосредственной близости к каждому ребру и подавлении реберных структур в сторону легочной ткани.

7. КЛАССИФИКАЦИЯ ИЗОБРАЖЕНИЙ

Классификатор используется для обнаружения аномальных изображений (изображений с патологией). Для классификации изображений используем конкурирующую вероятностную нейронную сеть (CPNN), которая относительно нечувствительна к отклонениям и генерирует точно спрогнозированные оценки вероятности.

Алгоритм CPNN имеет дополнительный уровень (т.е. уровень конкуренции), который возникает между вычислением гауссовых ядер и условными вероятностями.

Конкурентный уровень вводит два дополнительных этапа, которые включают в себя новые функции CPNN. На первом этапе этого уровня значения сортируются и ранжируются в порядке убывания. Все ядра соревнуются за включение в вычисление условной вероятности для соответствующего класса, но используется только часть. Аппроксимация может быть достигнута путем усреднения многомерных нормальных гауссовых ядер, которые являются произведением их собственных одномерных ядер и центрированы в каждом из известных образцов. Однако этот метод усреднения не ограничивается гауссовыми распределениями [11].

Распределение Гаусса $X_{Ci,j}$ в обычном методе PNN равно:

$$W_{i,j} = \frac{1}{(2\pi)^{\frac{d}{2}}\sigma^d} \cdot \exp\left(-\frac{(x_{new}-x_{Ci,j})^T \cdot (x_{new}-x_{Ci,j})}{2\sigma^2}\right), \quad (15)$$

в котором $|C|_i$ – мощность подмножества Ci , а член $W_{i,j}$ – многомерное нормальное (не особое) ядро и σ (разброс) является регулируемым параметром, который определяется экспериментально и для нормализованных входных векторов может принимать значение в диапазоне от 0 до 1; $XC_{i,j}$ является входом классификации, например, j-тые данные, которые принадлежат классу C_i . Однако показано, что оцененный отклик не очень чувствителен к изменениям σ.

Если S включает входные данные для классов NC, то его можно разделить на подмножества NC C i , которые содержат входные данные, т.е.

$$C_i = \{XC_{i,1}, XC_{i,2}, ..., X_{Ci,|C\,i|}\}). \quad (16)$$

Количество выбранных ядер в классе i указывается как количество победителей (NW_i). Отношение γ_i определяется как отношение NW_i к общему количеству ядер в каждом классе i:

$$\gamma_i = NW_i / |C_i| \rightarrow NW_i = [\gamma_i |C_i|]. \quad (17)$$

Это соотношение γ_i нормализовано и ограничено:

$$\gamma_{i\,min} = 1 / |C_i| \leq \gamma_i \leq 1. \quad (18)$$

Традиционный подход PNN можно рассматривать как особую форму CPNN с γ_i = 1 для всех классов. Подобно параметру расширения в PNN, σ и параметры γ_i являются функцией обучающих наборов данных, а их величины следует оптимизировать для достижения максимальной производительности. Следовательно, есть параметры NC+1 для оптимизации в методе CPNN. Используется двухуровневая оптимизация, при которой оптимизация по σ рассматривается как задача верхнего уровня, а оптимизация параметров γ_i рассматривается как задачи нижнего уровня [1]. При оптимизации верхнего уровня предполагается, что все γ_i остаются постоянными и равными единице. Рассматриваются множественные значения σ, и его оптимальное значение выбирается таким образом, чтобы производительность CPNN была максимальной. Это идентично подходу оптимизации параметра расширения в PNN. На нижнем уровне, используя полученный оптимум σ, параметры γ_i оптимизируются. В методе CPNN каждый класс имеет свой собственный

параметр γ, и каждый параметр класса γ оптимизируется отдельно от γ в других классах.

Архитектура метода CPNN приведена на рисунке 19.

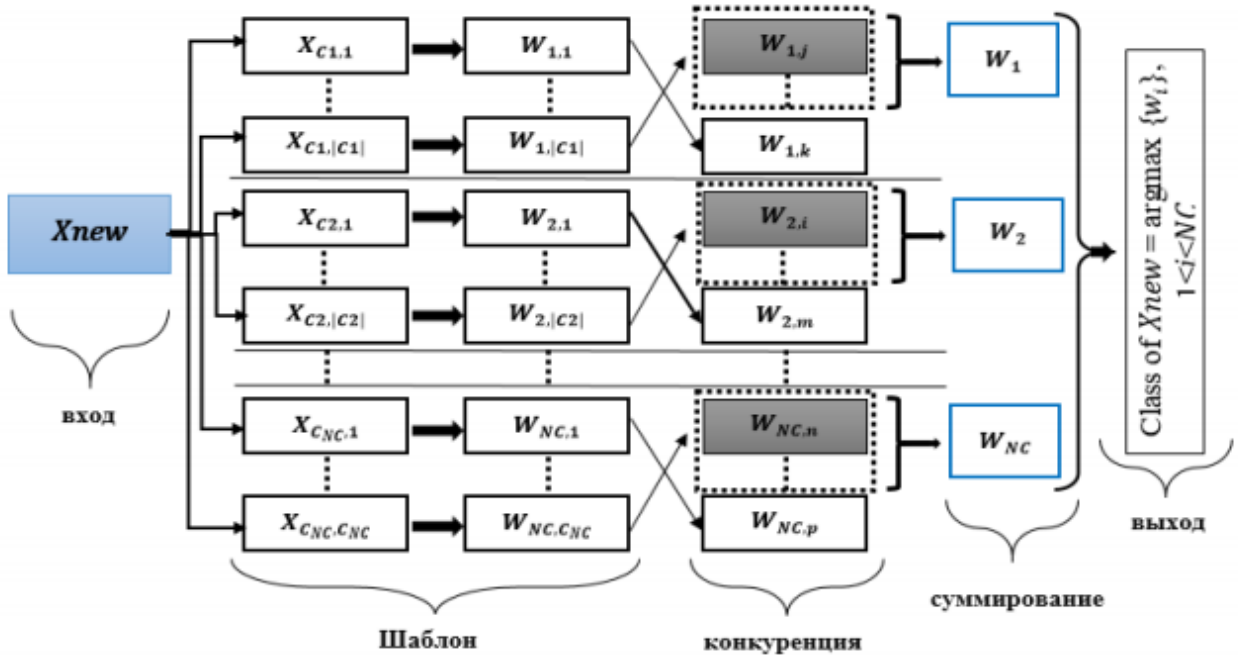

Рисунок 19 - Архитектура метода CPNN

Выводы по 7 разделу: приведена вычислительная методика и алгоритм обработки и анализа изображений на основе усовершенствованного алгоритма CPNN для распознавания патологий на снимках грудной клетки.

8. РЕЗУЛЬТАТЫ ЧИСЛЕННЫХ ЭКСПЕРИМЕНТОВ

Была проведена классификация рентгеновских снимков легких. Для проверки точности классификатора CPNN проведено обучение по совместному набору изображений из наборов данных NIH Chest X-rays Dataset и снимков, предоставленных ГБУЗ «ЧОКПТД».

Рентгеновские снимки медицинского учреждения были предоставлены в формате DICOM, обработаны согласно методике, приведенной в разделе 5, и преобразованы в формат PNG с помощью конвертора данных.

Точность классификации CPNN отдельно проверена на наборах изображений. Результаты экспериментов приведены в таблице 4.

Таблица 4 - Результаты экспериментов

	Количество изображений, тыс.	Классифицировано, тыс.		Классифицировано, тыс.	
		правильно	неправильно	правильно	неправильно
Общее количество	125	104	21	121	4
Изображения без патологии	75	63	12	73	2
Изображения с патологией	50	41	9	48	2

Проведем оценку качества приведенного алгоритма, используя F-меру.

Точность (precision) и полнота (recall) являются метриками которые используются при оценке большей части алгоритмов извлечения информации. Иногда они используются сами по себе, иногда в качестве базиса для производных метрик, таких как F-мера или R-Precision. Суть точности и полноты очень проста.

Точность системы в пределах класса – это доля снимков действительно принадлежащих данному классу относительно всех снимков, которые система от-

несла к этому классу. Полнота системы – это доля найденных классификатором снимков принадлежащих классу относительно всех снимков этого класса в тестовой выборке.

Эти значения легко рассчитать на основании таблицы контингентности, которая составляется для каждого класса отдельно (рисунок 20).

Категория i		Экспертная оценка	
		Положительная	Отрицательная
Оценка системы	Положительная	TP	FP
	Отрицательная	FN	TN

Рисунок 20 – Таблица контингентности

В таблице содержится информация сколько раз система приняла верное и сколько раз неверное решение по снимкам заданного класса. А именно:

TP— истинно-положительное решение;

TN — истинно-отрицательное решение;

FP — ложно-положительное решение;

FN — ложно-отрицательное решение.

Тогда, точность и полнота определяются следующим образом:

$$Precision=TP/(TP+FP)$$

$$Recall=TP/(TP+FN)$$

Чем выше точность и полнота, тем лучше.

Но в реальной жизни максимальная точность и полнота не достижимы одновременно, и приходится искать некий баланс. Поэтому, хотелось бы иметь некую метрику которая объединяла бы в себе информацию о точности и полноте нашего алгоритма. Именно такой метрикой является F-мера.

$$F=2\cdot Precision\cdot Recall/(Precision+Recall)$$

Оценка качества классификации изображений без корректировки изображений и после удаления с изображений реберной ткани приведена в таблицах 5 и 6.

Таблица 5 – Оценка качества классификации без корректировки изображений

Использованные снимки	Количество снимков, которые должны были попасть, %	Количество снимков, которые попали, %	Количество правильно попавших, %	Количество не попавших, %	Количество не правильно попавших, %
Общее количество	125	84	84	41	0
Изображения без патологии	75	53	53	22	0
Изображения с патологией	50	31	31	19	0

Изображения без патологии	Изображения с патологией
TP=53	TP=31
FP=0	FP=0
FN=22	FN=19
Precision==53/(53+0)=1	Precision==31/(31+0)=1
Recall=53/(53+22)=0.7	Recall=31/(31+19)=0.62
F=2·(1·0.7)/(1+0.7)=0.82	F=2·(1·0.62)/(1+0.62)=0.765

Таблица 6 – Оценка качества классификации с «удаленной» реберной тканью

Использованные снимки	Количество снимков, которые должны были попасть, %	Количество снимков, которые попали, %	Количество правильно попавших, %	Количество не попавших, %	Количество не правильно попавших, %
Общее количество	125	121	121	4	0
Изображения без патологии	75	73	73	2	0
Изображения с патологией	50	48	48	2	0

Изображения без патологии	Изображения с патологией
TP=73	TP=48
FP=0	FP=0
FN=2	FN=2
Precision==73/(73+0)=1	Precision==48/(48+0)=1
Recall=73/(73+2)=0.97	Recall=48/(48+9)=0.96
F=2·(1·0.97)/(1+0.97)=0.98	F=2·(1·0.96)/(1+0.96)=0.979

Наибольшее значение F-меры составило 0.98. Можно принять это значение за точность системы классификации изображения. Если предположить, что точность врача не ниже точности системы, тогда для определения ошибки совместной работы человека и системы можно применить теорему Кондорсе (Condorcet's

jury theorem). По теореме Кондорсе суммарная точность получается равной 0.98^3 + 3*0.98^2*(1 — 0.98) = 0.99

Повышение точность на 1% является значительным вкладом в анализ флюорографических снимков для социально значимых заболеваний, таких как туберкулез легких.

Выводы по 8 разделу: приведены результаты численных экспериментов. Проведена оценка качества приведенного алгоритма по критерию F-мера. Наибольшее значение F-меры показала сеть, обученная на снимках без костей. Значение составило 0.98. Исходя из результатов для варианта обучения на снимках с удаленными ребрами, общее улучшение составило 19,5%, что подтверждает пользу применения метода предварительного удаления реберной ткани с рентгеновских снимков при определении наличия патологий в легких.

ЗАКЛЮЧЕНИЕ

В выпускной квалификационной работе была проведена постановка задачи классификации медицинских изображений, определены цели, способствующие выполнению поставленной задачи. Сформулировано математическое описание поставленной задачи. Были собраны и подготовлены данные для проведения экспериментов.

Приведено алгоритмическое и математическое описание удаления обнаружения границ ребер на изображении и удаления реберной ткани. Приведена программа, реализующая данный алгоритм.

Проведены эксперименты с данными: классификация без предварительной обработки, классификация с удалением костной ткани с изображения. Проведена оценка качества приведенных классификаций с использованием F-меры.

Исходя из результатов проведенных экспериментов, сделан вывод о полезности и целесообразности применения метода предварительного удаления реберной ткани с рентгеновских снимков при определении наличия патологий в легких.

В качестве дальнейшего развития данной работы хочется отметить, что разработка и обоснование математических, алгоритмических, программно-аппаратных средств автоматической классификации сканируемых изображений имеет существенное значение для создания новых перспективных кластерных программных модулей. Она может повысить качество постановки диагноза, снизить пропуски заболеваний, а также значительно облегчить труд врачей.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Ali J. B. et al. Linear feature selection and classification using PNN and SFAM neural networks for a nearly online diagnosis of bearing naturally progressing degradations //Engineering Applications of Artificial Intelligence. – 2015. – Т. 42. – С. 67-81.

2. Atlas-based rib-bone detection in chest X-rays / S. Candemir, S. Jaeger, S. Antani et al. // Computerized Medical Imaging and Graphics. — 2016. — Vol. 51. — P. 32–39.

3. B.B. Ogul, P. Kosucu, A. Ozcam, S.D. Kanik, Lung noduledetection in X-ray images: a new feature set, in: Proceedings6th Conf. of the IFMBE, vol. 45, Dubrovnik, Croatia, 2015,pp. 150–155.

4. Chen M. Automated Segmentation of the Choroid in EDI-OCT Images with Retinal Pathology Using Convolution Neural Networks/ Min Chen, Jiancong Wang, Ipek Oguz, Brian L. VanderBeek, James C. Gee – Springer Cham, 2017 – 643 p.

5. Chih-Wei Hsu, Chih-Jen Lin A comparison of methods for multiclass support vector machines // IEEE Transactions on Neural Networks. – 2002, Volume 13, Issue: 2. – P. 415 - 425

6. Hasan S. M. A., Ko K. Depth edge detection by image-based smoothing and morphological operations //Journal of Computational Design and Engineering. – 2016. – Т. 3. – №. 3. – С. 191-197.

7. J. Toriwaki, J. Hasegawa, T. Fukumura, Y. Tagaki, Computeranalysis of chest photofluorograms and its application toautomated screening, Automedica 3 (1980) 63–81.

8. Jiang J., Trundle P., Ren J. Medical image analysis with artificial neural networks //Computerized Medical Imaging and Graphics. – 2010. – Т. 34. – №. 8. – С. 617- 631.

9. Laptin Yu., Likhovid A. P., Vinogradov A.P. Approaches to Construction of Linear Classifiers in the Case of Many Classes // Pattern Recognition and Image Analysis, Vol. 20, No. 2, 2010, p. 137-145.

10. Liu J. Radial Basis Function (RBF) Neural Network Control for Mechanical Systems: Design, Analysis and Matlab Simulation. – Springer Berlin Heidelberg, 2018 – 365 p.

11. Rakotomamonjy, A. BCI competition III: Dataset II-ensemble of SVMs for BCI P300 speller / A. Rakotomamonjy, V. Guigue // IEEE Transactions on Biomedical Engineering. – 2008. - No. 55(3). – Pp. 1147–1154.

12. Shanmuganathan S. Artificial Neural Network Modelling / Subana Shanmuganathan, Sandhya Samarasinghe. – Springer International Publishing, 2016. – 472 p.

13. Shor N. Z. Nondifferentiable Optimization and Polynomial Problems. – Amsterdam / Dordrecht / London: Kluwer Academic Publishers, 1998. – 381 p.

14. Smola A.J., Scheolkopf B. A Tutorial on Support Vector Regression // Statistics and Computing. 2004. N. 14. P. 199 – 222.

15. Tap J. Apply Convolutional Neural Network to Lung Nodule Detection: Recent Progress and Challenges/ Jiaxing Tan, YumeiHuo, Zhengrong Liang, Lihong Li– Springer Charm, 2017 – 221 p.

16. Wang L. Study on Image Classification with Convolution Neural Networks/ Lei Wang, Yanning Zhang, Runping Xi – Springer Berlin Heidelberg, 2017 – 235 p.

17. Yurii I. Zhuravlev, Yuryi Laptin, Alexander Vinogradov, Nikolay Zhurbenko, Aleksey Likhovid. Nonsmooth optimization methods in the problems of constructing a linear classifier // Int Journal Information Models & Analyses (ISSN 1314-6416) 2012 Volume 1 Number 2 pp 103-111

18. Zhuravlev Yu., Laptin Yu., A.Vinogradov Minimization of empirical risk in linear classifier problem // New Trends in Classification and Data Mining, ITHEA, Sofia, Bulgaria, 2010. – Pages 9-15

19. Барбара Бэйтс, Линн Бикли, Роберт Хекельман и др. Энциклопедия клинического обследования больного, перевод с английского. Москва, Геотар медицина 2017. – 896 с.

20. Браженко Н.А. Туберкулез органов дыхания. Издательство: СпецЛит, 2017. – 368 с.

21. Воронцов К.Лекции по методу опорных векторов. http://www.ccas.ru/voron

22. Ганин, И.П. Интерфейс мозг-компьютер «на волне P300»: исследование эффекта номера стимулов в последовательности их предъявления / И.П. Ганин, С.Л. Шишкин, А.Г. Кочетова, А.Я. Каплан // Физиология человека. – 2012. – Т. 38, № 2. – С. 5-13.

23. Журавлев Ю.И., Лаптин Ю.П., Виноградов А.П. Минимизация эмпирического риска и задачи построения линейных классификаторов // Кибернетика и системный анализ. 2011, № 4.- С. 155 – 164.

24. Зотин А. Г. и др. Алгоритмы анализа экспериментальных медицинских данных //Тезисы Международной конференции «АПВПМ». – Федеральное государственное бюджетное учреждение науки «Институт вычислительной математики и математической геофизики» Сибирского Отделения Российской академии наук, 2019. – №. 2019.

25. Калитеевский П. Ф. Макроскопическая дифференциальная диагностика патологических процессов. 2-е изд. М.: Медицина, 2019. – 463 с.

26. Кириллова С. В. и др. Вычислительная методика обработки медицинских изображений: выщеление границ //Медицина и высокие технологии. – 2018. – №. 1. – С. 14-19.

27. Конвертер файлов. URL: https://convertio.co/ru/ (дата обращения: 01.03.2020).

28. Лаптин Ю.П. Один подход к решению нелинейных задач оптимизации с ограничениями // Кибернетика и системный анализ. 2009, № 3. С. 182 – 187.

29. Лаптин Ю.П., Лиховид А.П. Использование выпуклых продолжений функций для решения нелинейных задач оптимизации // Управляющие машины и системы. 2010, № 6. – С. 25–31.

30. Машинное обучение: виды, алгоритмы, примеры [Электрон. ресурс] // Генеральный директор. – Персональный журнал руководителя - Режим доступа: https://www.gd.ru.

31. Мустафаев А.Г. Применение искусственных нейронных сетей для ранней диагностики заболевания сахарным диабетом // Кибернетика и программирование. 2018. №2. С. 1 - 7.

32. Назаренко А.В. Компьютерное зрение. Современный подход. Издательство: Вильямс, 2017. – 928 с.

33. Нессонова М.Н. Метод рейтингового голосования комитета алгоритмов в задачах классификации с учителем // Запорожский медицинский журнал. – 2013. – № 1 (76). – С. 101–102

34. Никулин В.Н., Палешева С.А., Зубарева Д.С. Об однородных ансамблях при использовании метода бустинга в приложении к классификации несбалансированных данных // Вестник пермского университета. Серия: Экономика. – 2012. – № 4. – С. 8–14

35. Обзор открытых источников данных медицинских изображений для машинного обучения [Электронный ресурс] / Гусев Александр, к.т.н., эксперт К-МИС. Доступ: www.kmis.ru/blog/obzor-otkrytykh-istochnikov-dannykh-meditsinskikh-izobrazhenii-dlia-mashinnogo-obucheniia

36. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2019. - 344 с.

37. Панченко О.Л., Пацей Н.В. МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ// 69-я НТК студентов и магистрантов: сб. науч. работ: в 4-х ч. 2-13 апреля 2018 г. – Минск: БГТУ,2018. – Ч. 4. – С.328-331.

38. Петер Ф. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных. Издательство: ДМК Пресс, 2017. – 400 с.

39. Петунин Ю.И, Шульдешов Г.А. Проблемы распознавания образов с помощью линейных дискриминантных функций Фишера // Кибернетика. – 1979. – № 6. – С. 134-137.

40. Попов А.К., Трофимов А.Г. Применение комитетов классификаторов в задаче классификации многомерных динамических данных // Новый университет. – 2012. – № 4(10). – С. 34–37.

41. Привес М.Г. Анатомия человека. М. Медицина, 2016. – 115 с.

42. Рублев Б.В., Петунин Ю.И., Литвинко П.Г. Структура гомотетичных линейно разделимых множеств в n-мерном евклидовом пространстве. – Кибернетика и системный анализ. Ч.1 – 1992. – № 1. – С. 3-15; Ч.2 – 1992. – № 2. – С. 23-33.

43. Саймон Хайкин, Нейронные сети. Полный курс. М.: Вильямс, 2016. – 363 с.

44. Симонов К. В. и др. Алгоритмы геометрического анализа медицинских изображений //Информатизация и связь. – 2019. – №. 4. – С. 95-101.

45. Синюк В.Г. Гибкие нейро-нечеткие системы вывода и программная реализация для решения задач аппроксимации / В.Г. Синюк, Е.Л. Бакшеева // Молодой ученый. – 2014. –№8. – С. 108-112.

46. Скрипачев В. О. Формат данных DICOM и возможности его обработки-средствами IDL [Текст] / В. А. Скрипачев, А. П. Пирхавка // Геоматика, 2014. - №3. - С. 32-36.

47. Степанова М. Д., Самодумкин С. А., Лемешева Т. Л. Математические методы диагностики в медицинских интеллектуальных системах: Учебно-методическое пособие по курсу «Прикладные интеллектуальные системы и системы принятия решений» для студентов специальности Т 10.04.00 «Искусственный интеллект». Мн.: БГУИР, 2001 – 44 с.

48. Стюарт Рассел, Искусственный интеллект. Современный подход. Издательство: Вильямс, 2018. – 1408 с.

49. Уэс Маккинни, Python и анализ данных. Издательство: ДМК Пресс, 2017. – 428 с.

50. Хамад Ю. А. Разработка и исследование алгоритмов сегментации и распознавания объектов на медицинских изображениях на основе шиарлет-преобразования и нейронных сетей: дис. канд. технич. наук. Сибирский федеральный университет, Красноярск, 2020.

51. Хамад Ю. А., Капсаргин Ф. П., Симонов К. В. Алгоритмы обнаружения и распознавания локальных областей на изображениях // Информатизация и Связь. – 2020. – № 3. – С. 25-34.

52. Шлезингер М., Главач В. Десять лекций по статистическому и структурному распознаванию. – К.: Наукова думка, 2004. – 545 с.

ПРИЛОЖЕНИЕ А - Основные теги структуры DICOM файла

Tag	Name
(0002,0000)	File Meta Information Group Length
(0002,0001)	File Meta Information Version
(0002,0002)	Media Storage SOP Class UID
(0002,0003)	Media Storage SOP Instance UID
(0002,0010)	Transfer Syntax UID
(0002,0012)	Implementation Class UID
(0002,0013)	Implementation Version Name
(0002,0016)	Source Application Entity Title
(0002,0017)	Sending Application Entity Title
(0002,0018)	Receiving Application Entity Title
(0002,0100)	Private Information Creator UID
(0002,0102)	Private Information
(0004,1130)	File-set ID
(0004,1141)	File-set Descriptor File ID
(0004,1142)	Specific Character Set of File-set Descriptor File
(0004,1200)	Offset of the First Directory Record of the Root Directory Entity
(0004,1202)	Offset of the Last Directory Record of the Root Directory Entity
(0004,1212)	File-set Consistency Flag
(0004,1220)	Directory Record Sequence
(0004,1400)	Offset of the Next Directory Record
(0004,1410)	Record In-use Flag
(0004,1420)	Offset of Referenced Lower-Level Directory Entity
(0004,1430)	Directory Record Type
(0004,1432)	Private Record UID
(0004,1500)	Referenced File ID
(0004,1504)	MRDR Directory Record Offset
(0004,1510)	Referenced SOP Class UID in File
(0004,1511)	Referenced SOP Instance UID in File
(0004,1512)	Referenced Transfer Syntax UID in File
(0004,151A)	Referenced Related General SOP Class UID in File
(0004,1600)	Number of References
(0008,0001)	Length to End
(0008,0005)	Specific Character Set
(0008,0006)	Language Code Sequence
(0008,0008)	Image Type
(0008,0010)	Recognition Code
(0008,0012)	Instance Creation Date
(0008,0013)	Instance Creation Time

(0008,0014)	Instance Creator UID
(0008,0015)	Instance Coercion DateTime
(0008,0016)	SOP Class UID
(0008,0018)	SOP Instance UID
(0008,001A)	Related General SOP Class UID
(0008,001B)	Original Specialized SOP Class UID
(0008,0020)	Study Date
(0008,0021)	Series Date
(0008,0022)	Acquisition Date
(0008,0023)	Content Date
(0008,0024)	Overlay Date
(0008,0025)	Curve Date
(0008,002A)	Acquisition DateTime
(0008,0030)	Study Time
(0008,0031)	Series Time
(0008,0032)	Acquisition Time
(0008,0033)	Content Time
(0008,0034)	Overlay Time
(0008,0035)	Curve Time
(0008,0040)	Data Set Type
(0008,0041)	Data Set Subtype
(0008,0042)	Nuclear Medicine Series Type
(0008,0050)	Accession Number
(0008,0051)	Issuer of Accession Number Sequence
(0008,0052)	Query/Retrieve Level
(0008,0053)	Query/Retrieve View
(0008,0054)	Retrieve AE Title
(0008,0055)	Station AE Title
(0008,0056)	Instance Availability
(0008,0058)	Failed SOP Instance UID List
(0008,0060)	Modality
(0008,0061)	Modalities in Study
(0008,0062)	SOP Classes in Study
(0008,0064)	Conversion Type
(0008,0068)	Presentation Intent Type
(0008,0070)	Manufacturer
(0008,0080)	Institution Name
(0008,0081)	Institution Address
(0008,0082)	Institution Code Sequence
(0008,0090)	Referring Physician's Name
(0008,0092)	Referring Physician's Address
(0008,0094)	Referring Physician's Telephone Numbers

(0008,0096)	Referring Physician Identification Sequence
(0008,009C)	Consulting Physician's Name
(0008,009D)	Consulting Physician Identification Sequence
(0008,0100)	Code Value
(0008,0101)	Extended Code Value
(0008,0102)	Coding Scheme Designator
(0008,0103)	Coding Scheme Version
(0008,0104)	Code Meaning
(0008,0105)	Mapping Resource
(0008,0106)	Context Group Version
(0008,0107)	Context Group Local Version
(0008,0108)	Extended Code Meaning
(0008,010B)	Context Group Extension Flag
(0008,010C)	Coding Scheme UID
(0008,010D)	Context Group Extension Creator UID
(0008,010F)	Context Identifier
(0008,0110)	Coding Scheme Identification Sequence
(0008,0112)	Coding Scheme Registry
(0008,0114)	Coding Scheme External ID
(0008,0115)	Coding Scheme Name
(0008,0116)	Coding Scheme Responsible Organization
(0008,0117)	Context UID
(0008,0118)	Mapping Resource UID
(0008,0119)	Long Code Value
(0008,0120)	URN Code Value
(0008,0121)	Equivalent Code Sequence
(0008,0122)	Mapping Resource Name
(0008,0123)	Context Group Identification Sequence
(0008,0124)	Mapping Resource Identification Sequence
(0008,0201)	Timezone Offset From UTC
(0008,0300)	Private Data Element Characteristics Sequence
(0008,0301)	Private Group Reference
(0008,0302)	Private Creator Reference
(0008,0303)	Block Identifying Information Status
(0008,0304)	Nonidentifying Private Elements
(0008,0306)	Identifying Private Elements
(0008,0305)	Deidentification Action Sequence
(0008,0307)	Deidentification Action
(0008,1010)	Station Name
(0008,1030)	Study Description

ПРИЛОЖЕНИЕ Б – Код программы предварительной обработки изображений

Разработанное программное обеспечение позволяет вести базу изображений, в которой сопоставлена информация: диагноз, изображение файл DCIOM.

Тип ЭВМ: Процессор Intel(R) Celeron(R) CPU 1000M 1.80GHz.

Язык программирования: Delphi 7 + СУБД MS Access 2010.

Операционная система: Windows 7 или 10.

Объем программы: 933 KB.

Текст программы

```
unit Unit1;
interface
uses
  Windows, Messages, SysUtils, Variants, Classes, Graphics, Controls, Forms,
  Dialogs, Grids, DBGrids, DBCtrls, ADODB, DB, jpeg, StdCtrls, ExtCtrls,
  ExtDlgs, StrUtils;
type
 TGraphType = (gtBitmap, gtIcon, gtMetafile, gtJpeg);
  TForm1 = class(TForm)
    DBGrid1: TDBGrid;
    ADOConnection1: TADOConnection;
    ADOTable1: TADOTable;
    DataSource1: TDataSource;
    ADOQuery1: TADOQuery;
    Button1: TButton;
    DataSource2: TDataSource;
    DBImage1: TDBImage;
    OpenPictureDialog1: TOpenPictureDialog;
```

```
    DBNavigator1: TDBNavigator;
    Button2: TButton;
    OpenDialog1: TOpenDialog;
    DBMemo1: TDBMemo;
    Button3: TButton;
    Edit1: TEdit;
    Button4: TButton;
    procedure Button1Click(Sender: TObject);
    procedure Button2Click(Sender: TObject);
    procedure Button3Click(Sender: TObject);
    procedure Button4Click(Sender: TObject);
  private
    { Private declarations }
  public
    { Public declarations }
  end;
var
  Form1: TForm1;
implementation
{$R *.dfm}
procedure TForm1.Button1Click(Sender: TObject);
var
B: TBitmap;
begin
if OpenPictureDialog1.Execute then begin
 ADOTable1.Edit;
  B := TBitmap.Create;
  try
    B.LoadFromFile(OpenPictureDialog1.FileName);
```

```
    DBImage1.Picture.Assign(B);
  finally
    B.Free;
  end;
  ADOTable1.Post;
 end;
end;
procedure TForm1.Button2Click(Sender: TObject);
begin
if OpenDialog1.Execute then begin
 ADOTable1.Edit;
 Memo-
Field(ADOTable1.FieldByName('Files')).LoadFromFile(OpenDialog1.FileName);
 ADOTable1.UpdateRecord;
 end;
end;
procedure TForm1.Button3Click(Sender: TObject);
var a: string;
    i: longint;
begin
a:= Edit1.Text;
i:=Pos(a, DBMemo1.Lines.Text);
DBMemo1.SetFocus();
DBMemo1.SelStart:=Pos(a,DBMemo1.Lines.Text)-1;
DBMemo1.SelLength:=Length(a);
ADOTable1.Edit;
If i<> 0 then ADOTable1.FieldByName('Diagnosis').Value:= edit1.Text
        else ADOTable1.FieldByName('Diagnosis').Value:= 'Патология';
ADOTable1.Post;
```

```
end;

procedure TForm1.Button4Click(Sender: TObject);
begin

with Button4 do
if Caption = 'Изменить' then begin
            Edit1.Enabled:= True;
            Button4.Caption:= 'Сохранить';
          end
          else
          if Caption = 'Сохранить' then begin
            Edit1.Enabled:= False;
            Button4.Caption:= 'Изменить';
end;
end;
end.
```

ПРИЛОЖЕНИЕ В – Код программы удаления реберной ткани и классификации изображений

Разработанное программное обеспечение позволяет классифицировать изображение как нормальное или анормальное с использованием классификатора вероятностной нейронной сети (PNN).

Тип ЭВМ: Процессор Intel(R) Celeron(R) CPU 1000M 1.80GHz.

Язык программирования: MATLAB 2017.

Операционная система: Windows 7 или 10.

Объем программы: 344 KB.

Текст программы

```
function Load_MRI_Image_Callback(hObject, eventdata, handles)
% hObject handle to Load_MRI_Image
[FileName,PathName] = uigetfile('*.jpg;*.png;*.bmp','Pick an X-RAY Image');
if isequal(FileName,0)||isequal(PathName,0)
 warndlg('User Press Cancel');
else
 P = imread([PathName,FileName]);
 P = imresize(P,[256,256]);
 axes(handles.axes1)
 imshow(P);title('Chest X-RAY Image');
 handles.ImgData = P;
 guidata(hObject,handles);
end
% ---------------------------------------------------------------------
function Chest_tumor_segmen_Callback(hObject, eventdata, handles)
% hObject handle to Chest_tumor (see GCBO)
if handles.radio1.Value == 1
```

```
BCET=50;
elseif handles.radio2.Value == 1
 BCET=80;
 set(handles.radio1, 'Value', 0);
set(handles.radio3, 'Value', 0);
 elseif handles.radio3.Value == 1
 BCET=100;
 set(handles.radio1, 'Value', 0);
set(handles.radio2, 'Value', 0);
else
 helpdlg(' Chose the BCET ');
end
 if isfield(handles,'ImgData')
 I = handles.ImgData;
% to segment the tumor using FcM
 grayimage1 = rgb2gray(I);
 grayimage= imresize(grayimage1, [256 256])
 tic;
 grayimage=bcet(grayimage,BCET);
 figure,imshow(grayimage);
 colormap(jet);
 fim=mat2gray( grayimage);
 [bwfim1,level1]=fcmthresh(fim,1);
 BW2 = bwareaopen(bwfim1,400);
A=imcrop(BW2, [0 10 256 230 ]);
A= imclearborder(A);
A = imrotate(A,90)
sz=zeros(256,15)
outputImage=cat(2,A,sz);
```

```
 A = imrotate(outputImage,180)
 sz=zeros(256,10)
 A=cat(2,A,sz);
 Tumor = imrotate(A,90)
 out = imoverlay(grayimage, Tumor, [1 0 0])
% to segment the normal part of chest using Otsu
 x=bcet(grayimage,100);
img = im2bw(x,0.45);
chest = imfill(img,8,'holes');
chest = uint8(255 * mat2gray(chest));
 chest =output(chest);
% to remove extra size from normal chest
 A= imresize(chest, [234 234])
 A = imrotate( A,90);
 sz=zeros(234,11);
 A1=cat(2,A,sz);
 A = imrotate(A1,180);
 sz=zeros(234,11);
 A=cat(2,A,sz);
 normal_chest = imrotate(A,90);
 normal_chest = imrotate( normal_chest,180);
 sz=zeros(256,11);
 A=cat(2,normal_chest,sz);
 normal_chest = imrotate( A,180);
 Norma_size_of_Chest=cat(2,normal_chest,sz);
% Combine detected tumor and non-infected area of chest using DWT
 Chest_and_TumorAreas=fusion(Norma_size_of_Chest,Tumor);
boundchest=Norma_size_of_Chest-Tumor;
% contours detection
```

```
boundchest=edge(boundchest,'canny',0.3);
Norma_size_of_Chest_edges=edge(chest,'canny',0.3);
axes(handles.axes2)
 imshow(out);
 axes(handles.axes3)
 imshow(boundchest);
 hold on;
[B,L,N] = bwboundaries(Norma_size_of_Chest_edges);
for k=1:length(B),
 boundary = B{k};
 plot(boundary(:,2), boundary(:,1), 'white', 'LineWidth',1);
end
[B,L,N] = bwboundaries(boundchest);
for k=1:length(B),
 boundary = B{k};
plot(boundary(:,2), boundary(:,1), 'white', 'LineWidth',1);
end
 axes(handles.axes5)
 imshow(Tumor);
 axes(handles.axes6)
 imshow(Norma_size_of_Chest-Tumor);
 axes(handles.axes4)
 imshow(Chest_and_TumorAreas);
 colormap(winter);
hold on;
[B,L,N] = bwboundaries(chest);
for k=1:length(B),
 boundary = B{k};
 plot(boundary(:,2), boundary(:,1), 'm', 'LineWidth',3);
```

```
end
[B,L,N] = bwboundaries(boundchest);
for k=1:length(B),
 boundary = B{k};
 plot(boundary(:,2), boundary(:,1), 'yellow', 'LineWidth',2);
end
[B,L,N] = bwboundaries(Tumor);
for k=1:length(B),
 boundary = B{k};
 plot(boundary(:,2), boundary(:,1), 'r', 'LineWidth',2);
end
% to set the size of normal chest and tumor and processing time
 size_of_chest=img- BW2;
 size_of_tumor = sum(Tumor(:));
set(handles.edit20,'string',size_of_tumor);
 size_of_chest = (sum(size_of_chest(:)));
set(handles.edit21,'string',size_of_chest);
 PerSizeTumor=(size_of_tumor/size_of_chest)*100;
set(handles.edit22,'string',fix(PerSizeTumor));
timeElapsed = toc;
set(handles.edit23,'string',fix(timeElapsed));
% ------------------------------------------------------------------
function y=bcet(I,c) % Function of balance contrast enhancement
x = double(I); % INPUT IMAGE
Lmin = min(x(:)); % MINIMUM OF INPUT IMAGE
Lmax = max(x(:)); % MAXIMUM OF INPUT IMAGE
Lmean = mean(x(:)); %MEAN OF INPUT IMAGE
LMssum = mean(x(:).^2); %MEAN SQUARE SUM OF INPUT IMAGE
Gmin = 0; %MINIMUM OF OUTPUT IMAGE
```

```
Gmax = 255; %MAXIMUM OF OUTPUT IMAGE
Gmean =c ; %MEAN OF OUTPUT IMAGE for cancer tumor 75
bnum = Lmax.^2*(Gmean-Gmin) - LMssum*(Gmax-Gmin) + Lmin.^2*(Gmax-Gmean);
bden = 2*(Lmax*(Gmean-Gmin)-Lmean*(Gmax-Gmin)+Lmin*(Gmax-Gmean));
b = bnum/bden;
a = (Gmax-Gmin)/((Lmax-Lmin)*(Lmax+Lmin-2*b));
c = Gmin - a*(Lmin-b).^2;
y = a*(x-b).^2+c; %PARABOLIC FUNCTION
y = uint8(y);
% ------------------------------------------------------------------
function [bw,level]=fcmthresh(IM,sw) %FCMTHRESH Thresholding by 3-class fuzzy c-means
clustering
% check the parameters
if (nargin<1)
 error('You must provide an image.');
elseif (nargin==1)
 sw=0;
elseif (sw~=0 && sw~=1)
 error('sw must be 0 or 1.');
end
data=reshape(IM,[],1);
[center,member]=fcm(data,3);
[center,cidx]=sort(center);
member=member';
member=member(:,cidx);
[maxmember,label]=max(member,[],2);
if sw==0
```

```
 level=(max(data(label==1))+min(data(label==2)))/2;
else
 level=(max(data(label==2))+min(data(label==3)))/2;
end
bw=im2bw(IM,level);
% ----------------------------------------------------------------
function [BW5]=output(grayImage) % function of correction the boundaries /
mask of segmented
area
% mask = grayImage
mask = grayImage > 200; % Use for highlight edges
mask = bwconvhull(mask, 'Union');
% Now find the improved outer boundary using active contours.
BW5 = activecontour(grayImage, mask, 90, 'edge');
% ----------------------------------------------------------------
function fused=fusion(a,b) %function of combine the tumor and normal area of
chest
%% Wavelet Transform
 [a1,b1,c1,d1]=dwt2(a,'db2');
[a2,b2,c2,d2]=dwt2(b,'db2');
[k1,k2]=size(a1);
%% Fusion Rules %% Average Rule
for i=1:k1
 for j=1:k2
 a3(i,j)=(a1(i,j)+a2(i,j))/2;
 end
end
%% Max Rule
 for i=1:k1
```

```
 for j=1:k2
 b3(i,j)=max(b1(i,j),b2(i,j));
 c3(i,j)=max(c1(i,j),c2(i,j));
 d3(i,j)=max(d1(i,j),d2(i,j));
 end
end
 %% Inverse Wavelet Transform
fused=idwt2(a3,b3,c3,d3,'db2');
%-----------------------------------------------------------------------------------------
function_tumor_Classify_Callback(hObject, eventdata, handles)
handles.ImgData2 = P;
P=bcet(P,110);
Detected_Tumor = im2bw(P);
% features extraction using DWT
guidata(hObject,handles);
[cA1,cH1,cV1,cD1] = dwt2(Detected_Tumor,'db4');
[cA2,cH2,cV2,cD2] = dwt2(cA1,'db4');
[cA3,cH3,cV3,cD3] = dwt2(cA2,'db4');
DWT_feat = [cA3,cH3,cV3,cD3];
G = pca(DWT_feat);
whos DWT_feat
whos G
g = graycomatrix(G);
stats = graycoprops(g,'Contrast Correlation Energy Homogeneity');
Contrast = stats.Contrast;
Correlation = stats.Correlation;
Energy = stats.Energy;
Homogeneity = stats.Homogeneity;
Mean = mean2(G);
```

```
Standard_Deviation = std2(G);
Entropy = entropy(G);
RMS = mean2(rms(G));
%Skewness = skewness(img)
Variance = mean2(var(double(G)));
a = sum(double(G(:)));
Smoothness = 1-(1/(1+a));
Kurtosis = kurtosis(double(G(:)));
Skewness = skewness(double(G(:)));
% Inverse Difference Movement
m = size(G,1);
n = size(G,2);
in_diff = 0;
for i = 1:m
 for j = 1:n
 temp = G(i,j)./(1+(i-j).^2);
 in_diff = in_diff+temp;
 end
end
IDM = double(in_diff);

feat = [Contrast,Correlation,Energy,Homogeneity, Mean, Standard_Deviation,
Entropy, RMS,
Variance, Smoothness, Kurtosis, Skewness, IDM];
% classify the X-RAY image using SVM classifier
load Trainset.mat
xdata = meas;
group = label;
svmStruct1 = svmtrain(xdata,group,'kernel_function', 'linear');
```

```
species = svmclassify(svmStruct1,feat,'showplot',false);
 if strcmpi(species,'MALIGNANT')
 helpdlg(' Malignant Tumor ');
 disp(' Malignant Tumor ');
else
 helpdlg(' Benign Tumor ');
 disp(' Benign Tumor ');
end
set(handles.edit4,'string',species);
% Put the features in GUI
set(handles.edit5,'string',Mean);
set(handles.edit6,'string',Standard_Deviation);
set(handles.edit7,'string',Entropy);
set(handles.edit8,'string',RMS);
set(handles.edit9,'string',Variance);
set(handles.edit10,'string',Smoothness);
set(handles.edit11,'string',Kurtosis);
set(handles.edit12,'string',Skewness);
set(handles.edit13,'string',IDM);
set(handles.edit14,'string',Contrast);
set(handles.edit15,'string',Correlation);
set(handles.edit16,'string',Energy);
set(handles.edit17,'string',Homogeneity);
end
% ------------------------------------------------------------------
function y=bcet(I,c) % Function of balance contrast enhancement
x = double(I); % INPUT IMAGE
Lmin = min(x(:)); % MINIMUM OF INPUT IMAGE
Lmax = max(x(:)); % MAXIMUM OF INPUT IMAGE
```

```
Lmean = mean(x(:)); %MEAN OF INPUT IMAGE
LMssum = mean(x(:).^2); %MEAN SQUARE SUM OF INPUT IMAGE
Gmin = 0; %MINIMUM OF OUTPUT IMAGE
Gmax = 255; %MAXIMUM OF OUTPUT IMAGE
Gmean =c ; %MEAN OF OUTPUT IMAGE for cancer tumor 75
bnum = Lmax.^2*(Gmean-Gmin) - LMssum*(Gmax-Gmin) + Lmin.^2*(Gmax-Gmean);
bden = 2*(Lmax*(Gmean-Gmin)-Lmean*(Gmax-Gmin)+Lmin*(Gmax-Gmean));
b = bnum/bden;
a = (Gmax-Gmin)/((Lmax-Lmin)*(Lmax+Lmin-2*b));
c = Gmin - a*(Lmin-b).^2;
y = a*(x-b).^2+c; %PARABOLIC FUNCTION
y = uint8(y);
% ------------------------------------------------------------------
```