

Федеральное государственное автономное образовательное  
учреждение высшего образования  
«СИБИРСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»

На правах рукописи



Хамад Юсиф Ахмед

**РАЗРАБОТКА И ИССЛЕДОВАНИЕ АЛГОРИТМОВ СЕГМЕНТАЦИИ И  
РАСПОЗНАВАНИЯ ОБЪЕКТОВ НА МЕДИЦИНСКИХ  
ИЗОБРАЖЕНИЯХ НА ОСНОВЕ ШИАРЛЕТ-ПРЕОБРАЗОВАНИЯ И  
НЕЙРОННЫХ СЕТЕЙ**

Специальность 05.13.17 – Теоретические основы информатики

Диссертация на соискание ученой степени  
кандидата технических наук

Научный руководитель –  
доктор технических наук  
Симонов К.В.

Красноярск – 2020

## ОГЛАВЛЕНИЕ

<b>ГЛАВА 1. ИССЛЕДОВАНИЕ АЛГОРИТМОВ СЕГМЕНТАЦИИ, РАСПОЗНАВАНИЯ ОБРАЗОВ И ОПРЕДЕЛЕНИЯ КОНТУРОВ</b>	<b>11</b>
<b>1.1. Приложения нейронной сети в компьютерной диагностике</b> .....	<b>12</b>
<b>1.2. Теоретические основы обработки визуальных данных нейросетями</b> .....	<b>13</b>
1.2.1 Базовая структура нейронной сети .....	14
<b>1.3 Нейронные сети для компьютерной диагностики / обнаружения</b> .....	<b>18</b>
1.3.1. Обнаружение и диагностика объекта (онкологии молочной железы) ...	19
1.3.2. Обнаружение и диагностика локального объекта (патологий в легких)	21
1.3.3. Обнаружение и диагностика объекта на МРТ снимках (опухоли головного мозга) .....	24
<b>1.4. Извлечение информативных признаков</b> .....	<b>25</b>
1.4.1. Дискретное вейвлет-преобразование (DWT) .....	27
1.4.2. Матрица когерентности серого уровня (GLCM) .....	29
<b>1.5. Алгоритмы обнаружения контуров</b> .....	<b>30</b>
1.5.1. Обнаружение контуров изображения на основе улучшенного оператора Кэнни.....	32
<b>1.6. Выводы по первой главе</b> .....	<b>35</b>
 <b>ГЛАВА 2. АЛГОРИТМЫ СЕГМЕНТАЦИИ И КЛАССИФИКАЦИИ ЛОКАЛЬНЫХ ОБЛАСТЕЙ НА ИЗОБРАЖЕНИЯХ (МРТ И КТ)</b>	 <b>37</b>
<b>2.1. Методы обработки и анализа локальных областей на изображениях</b> .....	<b>37</b>
<b>2.2. Алгоритмическая процедура сегментации и классификации локальных областей (опухолей) на изображениях</b> .....	<b>40</b>
2.2.1. Улучшение контрастности изображений .....	42
2.2.2. Метод сегментации объектов .....	44
2.2.3. Детектирование и контурирование объектов .....	47
2.2.4. Извлечение признаков.....	49
2.2.5. Классификация локальных объектов (опухолей) .....	50
<b>2.3. Вычислительные эксперименты</b> .....	<b>54</b>
<b>2.4. Выводы по второй главе</b> .....	<b>64</b>
 <b>ГЛАВА 3. РАЗРАБОТКА МЕТОДИКИ И АЛГОРИТМИЧЕСКОЕ ОБЕСПЕЧЕНИЕ ОБРАБОТКИ И АНАЛИЗА ИЗОБРАЖЕНИЙ</b>	 <b>66</b>
<b>3.1. Обзор современных подходов к обработке и анализу изображений СХР и КТ</b> .....	<b>66</b>
<b>3.2. Вычислительная методика обработки и анализа снимков</b> .....	<b>70</b>
3.2.1. Общая алгоритмическая блок-схема .....	70

3.2.2. Предварительная обработка рентгенограмм грудной клетки .....	71
3.2.3. Сегментация CXR на основе метода вейвлет-порога .....	74
3.2.4. Шиарлет-преобразование для обнаружения контуров .....	77
3.2.5. Извлечение признаков .....	80
3.2.6. Классификация патологии на снимках CXR .....	81
<b>3.3. Результаты численных экспериментов .....</b>	<b>86</b>
3.3.1. База данных изображений и расчеты .....	86
3.3.2. Оценка показателей эффективности и точности .....	88
<b>3.4. Выводы по третьей главе .....</b>	<b>92</b>
<b>ГЛАВА 4. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ .....</b>	<b>94</b>
<b>4.1. Постановка задачи в рамках медицинского эксперимента .....</b>	<b>95</b>
<b>4.2. Сравнительный анализ методов количественной гистологии .....</b>	<b>97</b>
4.2.1. Описание медицинского эксперимента .....	99
<b>4.3. Способ анализа экспериментальных медицинских изображений .....</b>	<b>103</b>
4.3.1. Предварительная обработка: шумоподавление .....	104
4.3.2. Коррекция яркости с контрастным усилением .....	106
4.3.3. Формирование контурного представления .....	108
4.3.4. Цветовое кодирование объектов на изображении .....	111
4.3.5. Сегментация экспериментальных изображений .....	113
<b>4.4. Результаты экспериментальных исследований .....</b>	<b>115</b>
4.4.1. Описание экспериментальных медицинских данных .....	115
4.4.2. Оценка параметров яркости изображений .....	117
4.4.3. Оценка показателей и параметров в эксперименте .....	120
<b>4.5. Выводы по четвертой главе .....</b>	<b>126</b>
<b>ЗАКЛЮЧЕНИЕ .....</b>	<b>128</b>
<b>СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ .....</b>	<b>130</b>
<b>ПРИЛОЖЕНИЕ А – Программа для ЭВМ: «Сегментация и классификация локальных объектов (опухолей головного мозга) на изображениях МРТ» .....</b>	<b>144</b>
<b>ПРИЛОЖЕНИЕ Б – Программа для ЭВМ: «Алгоритмическое и программное обеспечение обработки и анализа изображений компьютерной томографии и рентгенографии грудной клетки» .....</b>	<b>152</b>
<b>ПРИЛОЖЕНИЕ В – Результаты экспериментальных исследований распознавания патологии и определения границ легких .....</b>	<b>165</b>

## ВВЕДЕНИЕ

**Актуальность работы.** В направлениях современной медицины активно развивается новая область обработки и анализа визуальных данных – радиомика – компьютерная технология, которая позволяет более глубоко анализировать медицинские изображения, такие как компьютерная томография (КТ), магнитно-резонансная томография (МРТ), рентгенография грудной клетки (СХР) и др. [7, 31, 44, 46, 101, 130, 160].

Этот подход позволяет извлекать количественные текстурные признаки из изображений и выделять биологические маркеры для описания патологии (опухоли), что обеспечивает персонафицированный подход к диагностике и лечению [1, 3, 6, 22, 58, 127, 142]. Развитие информационных технологий – спектральная декомпозиция и нейросети для обработки и анализа визуальных данных являются приоритетным подходом для решения подобного рода прикладных задач [13, 21, 38, 88, 94, 98, 114, 132, 174].

В тоже время в процессе распознавания образов в изображениях при принятии решений медицинские специалисты сталкиваются с рядом проблем: неполная и неточная исходная информация; большая изменчивость атрибутов и небольшие размеры выборки; ограниченное время принятия решений для заключений [9, 22, 25, 40, 64]. Эти факторы часто приводят к ошибкам в диагностике. В целях повышения эффективности и качества обработки экспериментальной информации необходимо усовершенствовать и модифицировать методы анализа визуальных данных, как для повышения качества медицинских изображений, так для повышения точности распознавания объектов.

Одной из главных целей компьютерного зрения является интерпретация окружающего пространства (сцены). Методы сегментации, выделения границ и распознавание образов играют важную роль, так как они используются в качестве основного этапа обработки данных в большинстве задач компьютерного зрения и компьютерной диагностики [25, 38, 40, 147, 164].

Это направление охватывает практически все области, связанные с медицинскими экспериментальными исследованиями. В теоретическом плане распознавание образов можно выделить в отдельный класс задач, связанных с сегментацией и распознаванием трехмерных визуальных объектов, при этом сегментация является одним из этапов задачи распознавания объекта [31, 36, 109, 157].

В последнее десятилетие активно развивается аппаратное обеспечение в экспериментальных медицинских исследованиях, появляются все более совершенные и сложные приборные комплексы. В то же время известные алгоритмические средства не вполне соответствуют требованиям по быстрдействию и качеству обработки сложных визуальных данных, регистрируемых вновь создаваемыми аппаратными средствами, а также возможностям для решения новых актуальных задач геометрического (морфологического, текстурного) анализа данных, основанного на вейвлет- и шиарлет-преобразованиях [42, 57, 144].

Шиарлет-преобразование является новым методом анализа многомерных данных. Этот метод отличается возможностью определения анизотропной составляющей в анализируемых данных, что может быть применимым для решения задач обработки изображений [58, 84, 90].

Идея шиарлет-преобразования опирается на хорошо разработанную теорию вейвлет-анализа и является её естественным расширением [21]. Так, параметрами шиарлет-преобразования являются не только смещение и коэффициент масштабирования, но и сдвиг (shear). Исследования по шиарлет-анализу в последние годы отмечены в работах [81, 82]. Шиарлет-преобразование позволяет работать с криволинейными сингулярностями, учитывать анизотропные свойства исследуемой среды (объекта).

Для решения новых задач необходимо модифицировать вычислительную технологию геометрического (морфологического, текстурного) анализа визуальных данных за счет обеспечения возможности выбора алгоритмов шиарлет-преобразования и алгоритмов машинного обучения в виде

вероятностной нейронной сети (PNN), что позволит повысить точность выделения линейных структур, визуальное качество изображений изучаемых объектов и их контуров [104, 109, 128, 133, 148, 160].

Актуальными также являются теоретические и прикладные исследования по усовершенствованию алгоритмов, связанных с применением нейронных сетей в рамках единой вычислительной технологии для решения задач оценки состояния объекта (выявление и классификация патологий и новообразований) на медицинских изображениях (СХR-сканирование, КТ и МРТ-снимки) [25, 88, 98, 113, 114].

**Целью диссертационной работы** является повышение точности алгоритмов сегментации и распознавания объектов на изображениях для визуализации и интерпретации экспериментальных медицинских данных.

Для достижения цели поставлены следующие **задачи**:

1. Разработать и исследовать метод сегментации локальных областей (с патологией) на медицинских изображениях (МРТ и КТ).
2. Разработать и исследовать быстрый алгоритм классификации локальных областей в комплексной диагностике (на примере злокачественных новообразований молочной железы и головного мозга).
3. Разработать и исследовать высокоточный метод обнаружения границ объектов на основе модифицированного метода сегментации.
4. Разработать вычислительную методику для выделения объектов и распознавания патологии на изображениях рентгенографии грудной клетки (СХR и КТ).
5. Провести экспериментальные исследования по оценке результативности разработанных метода, алгоритмов в рамках комплексного медицинского эксперимента.

**Методы исследования.** Для решения поставленных в работе задач использовались методы теории цифровой обработки изображений, теории информации, методы теории распознавания образов и анализа данных, методы объектно-ориентированного программирования.

**Научная новизна.** При решении поставленных в диссертационной работе задач получены следующие новые научные результаты:

1. Разработан новый метод автоматической сегментации по отдельным объектам, отличающийся использованием комбинации порогового значения Оцу и нечеткой кластеризации, который позволяет улучшить точность выделения отдельных объектов и классификации (на примере опухолей головного мозга и молочной железы).
2. Разработаны методика и алгоритмическое обеспечение обработки и анализа изображений (СХР и КТ), отличающиеся введением конкурентного уровня и дополнительных шагов для определения новых функций CPNN на основе метода машинного обучения, что позволяет повысить точность определения границ легких и уменьшить ошибки распознавания патологии на изображениях (СХР и КТ).
3. Разработан способ обнаружения и визуализации контуров, отличающийся использованием модифицированного шварц-преобразования (алгоритм FFST), который позволяет анализировать геометрические (морфологические, текстурные) особенности изображений (на примере оценки скорости роста тканей на имплантатах в медицинском эксперименте).

**Практическая значимость.** Разработанные алгоритмы сегментации и распознавания позволяют повысить эффективность обнаружения злокачественной опухоли на изображениях КТ и МРТ, а также повысить качество обнаружения патологий на рентгеновских снимках грудной клетки. Результаты обработки и анализа визуальных данных в экспериментальных исследованиях в герниопластике позволяют повысить качество поиска и описания соответствующих объектов, что вносит существенный вклад в обеспечение эффективности методов количественной гистологии.

**Основные результаты, выносимые на защиту:**

1. Метод автоматической сегментации отдельных объектов на медицинских изображениях.

2. Алгоритм классификации локальных объектов (на примере опухолей головного мозга и молочной железы) на изображениях (МРТ и КТ).
3. Методика и алгоритмическое обеспечение высокоточного выделения границ объектов (легких) и распознавания патологии на изображениях (СХР и КТ).
4. Способ обнаружения и контрастирования контуров объектов на изображении на основе шварц-преобразования (модифицированный алгоритм FFST).

**Внедрение результатов диссертационной работы.** Результаты диссертационного исследования переданы на кафедры общей хирургии и урологии КрасГМУ, в Грантовый центр и Центр восстановительной медицины СМКЦ ФМБА России. Также результаты диссертационного исследования внедрены в учебный процесс кафедры прикладной математики и компьютерной безопасности Института космических и информационных технологий СФУ. Оформлены документы для регистрации двух программ для ЭВМ в Роспатенте.

**Апробация работы.** Основные положения и результаты диссертационной работы представлялись на международных и всероссийских конференциях: Всероссийской научно-технической конференции студентов, аспирантов и молодых учёных (Красноярск, 2018-2019); XXI Всероссийском семинаре «Моделирование неравновесных систем» (Красноярск, 2018); XXVI Всероссийском семинаре «Нейроинформатика, её приложения и анализ данных» (Красноярск, 2019); XIX Всероссийском симпозиуме с международным участием «Сложные системы в экстремальных условиях» (Красноярск, 2018); Марчуковские чтения: Международной конференции «Актуальные проблемы вычислительной и прикладной математики» (Новосибирск, 2019); 22rd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems (Белград, Сербия, сентябрь 2018); 23rd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems (Будапешт, Венгрия, сентябрь 2019); 1st International Conference on Information and Sciences (AiCIS, Ирак, 2018); 9th International Conference on Information

Systems and Technologies (ACM, Египет, 2019); International Conference on Applied Computing to Support Industry: Innovation and Technology (ACRIT, Ирак, 2019), а также на научных семинарах в ИКИТ СФУ (2018–2020).

**Соответствие диссертации паспорту специальности.** Диссертационное исследование соответствует области исследований специальности 05.13.17 – Теоретические основы информатики по п. 5. «Разработка и исследование моделей и алгоритмов анализа данных, обнаружения закономерностей в данных и их извлечениях, разработка и исследование методов и алгоритмов анализа текста, устной речи и изображений» и п. 7. «Разработка методов распознавания образов, фильтрации, распознавания и синтеза изображений, решающих правил».

**Публикации.** Результаты диссертационного исследования опубликованы в 23 печатных работах, из них 10 статей в журналах, рекомендованных ВАК, 7 публикаций из источников, индексируемых в базе SCOPUS и WoS, 6 статей опубликованы в научно-технических журналах и сборниках, в трудах научных конференций.

**Личный вклад автора.** Основные научные результаты, аналитические выражения, доказательства, методы и алгоритмы, приведенные в диссертации, получены автором лично, либо при его непосредственном участии.

Вклад автора в статьи 1-4 составляет 75 %, в статьи 5-10 составляет 70%; в статьи 11-17 составляет 85 %; в статьи 18-23 составляет 65 %

**Структура и объем диссертации.** Диссертация состоит из введения, четырех глав, заключения и приложений. Полный объем диссертации – 171 страница текста, включая 39 рисунков и 21 таблицу. Список использованных источников содержит 186 позиций.

**Благодарности.** Автор глубоко признателен профессору д.ф.-м.н Носкову М.В. и профессору д.т.н. Симонову К.В., которые оказали большое влияние на формирование научных взглядов соискателя, за поддержку и внимание к диссертационной работе.

Также автор выражает благодарность коллегам и участникам совместных исследований: доценту к.т.н. А.Г. Зотину, М.А. Курако и специалистам медикам: д.м.н. Ф.П. Капсаргину, Е.М. Кабаеву, А.С. Кенц, Т.В. Черепановой.

## **ГЛАВА 1. ИССЛЕДОВАНИЕ АЛГОРИТМОВ СЕГМЕНТАЦИИ, РАСПОЗНАВАНИЯ ОБРАЗОВ И ОПРЕДЕЛЕНИЯ КОНТУРОВ**

Учитывая тот факт, что нейронные сети широко освещаются в сообществе исследователей и разработчиков алгоритмов для медицинской визуализации, в этой главе представляем обзор литературы о последних разработках вычислительных технологий на основе нейронных сетей: в области компьютерной диагностики, выделения признаков, классификации, распознавания образов, сегментации медицинских изображений, а также для обнаружения границ и анализа визуального контента. Обсуждается также описание медицинских изображений для их предварительной обработки и последующего анализа с целью повышения осведомленности о том, как нейронные сети могут применяться в этих областях, обеспечения основы для дальнейших исследований и практического применения.

Репрезентативные методы и алгоритмы объяснены подробно, чтобы предоставить примеры, иллюстрирующие: (i) как известную нейронную сеть с фиксированной структурой и процедурой обучения можно применять для решения задачи медицинской визуализации; (ii) как медицинские изображения могут быть обработаны, проанализированы и охарактеризованы нейронными сетями; (iii) как можно расширить нейронные сети для решения задач, связанных с медицинской визуализацией. В заключительном разделе представлен обзор сравнений между нейронными сетями, чтобы обеспечить обобщенный взгляд на искусственный интеллект, применительно к задаче медицинской визуализации.

Приводятся также краткие описания некоторых методов выделения краев и некоторых общих подходов к оценке алгоритмов классификации объектов (патологий) на рентгенографии (СХР) и компьютерной томографии (КТ) грудной клетки. Демонстрируется идея, лежащая в основе матрицы когерентности серого уровня (GLCM) и дискретного вейвлет-преобразования (DWT). Дается описание принципа компонентного анализа (РСА) как одного из эффективных методов извлечения и восстановления характеристик.

Представлен обзор различных подходов к применению методов машинного обучения на основе искусственных нейронных сетей (ИНС) и спектрального разложения на основе алгоритмов шварц-преобразования и Кэнни для решения задач обработки и анализа визуальной медицинской информации. Основные результаты исследований по данной главе опубликованы в работах автора [178, 179].

### **1.1. Приложения нейронной сети в компьютерной диагностике**

Приложения нейронной сети в компьютерной диагностике представляют основной поток вычислительного контента в медицинской визуализации [45, 107, 110, 117]. Их проникновение и участие являются всеобъемлющими для медицинских проблем, потому что: (i) нейронные сети имеют характер адаптивного обучения на основе входной информации и, используя подходящий алгоритм обучения, могут улучшить себя в соответствии с разнообразием и изменением входного контента; (ii) нейронные сети способны оптимизировать взаимосвязь между входами и выходами посредством распределенных вычислений, обучения и обработки, что приводит к надежным решениям, требуемым спецификациями; (iii) медицинский диагноз основывается на визуальном осмотре, а медицинская визуализация является наиболее важным инструментом для обеспечения диагностики.

Сегментация медицинских изображений и обнаружение краев остается распространенной и фундаментальной задачей для применений в медицинской визуализации [78]. Любой контент-анализ и проверка изучаемой области требуют сегментации выделенных областей, что может быть реализовано с помощью обнаружения краев и других методов.

Традиционные подходы характеризуются рядом хорошо изученных алгоритмов, включая моделирование [28, 32], обнаружение контуров и т.д. [135]. Для сравнения, нейросетевые подходы используют возможности механизма обучения для классификации медицинских изображений по областям,

соответствующим контенту, для завершения сегментации, а также для обнаружения границ [107].

В работах [107, 166] описаны методы медицинского визуального анализа, который играет важную роль в сегментации и анализе для медицинского применения в диагностике. Типичными примерами являются прогнозирование осложнений, наблюдение за состоянием здоровья пациента.

Другие применения ИНС включают компьютерное обнаружение рака легких [134, 138], улучшение изображения и подавление ребер на рентгенограммах грудной клетки с помощью обучения ИНС [136, 151], а также прогнозирование заболеваний [33] и др.

В последнее время актуальным является применение ИНС технологии для анализа пакетов медицинских изображений и новым объектом исследований становятся данные магнитно-резонансная томография (МРТ), где для моделирования функциональной связности используются определенные структурированные ИНС [76]. В связи с определенной аналогией ИНС и нейронов человека показано, что ИНС алгоритмы детектирования и сегментации весьма полезны для решения этой новой задачи [27].

## **1.2. Теоретические основы обработки визуальных данных нейросетями**

Нейронные сети являются относительно новой методологией программирования для компьютеров. Они отлично справляются со многими задачами, которые не могут быть выполнены традиционными методами, такими как распознавание образов.

Исследователи из Хьюстонского университета, штат Техас, разработали программу для точного определения формы опухолей мозга и шеи, и эта программа позволила онкологам более точно воздействовать на раковые клетки, особенно при определенных типах рака (в случае, когда другие слабые ткани находятся поблизости).

Ученые из Иокогамы в Японии разработали программное обеспечение, которое может обнаружить рак толстой кишки на ранних стадиях с точностью

86%, и эта точность превосходна, так как трудно определить этот тип рака до того, как опухоль станет злокачественной и опасной. Поэтому раннее обнаружение является важным и помогает улучшить результаты лечения.

Исследователи из King's College в Лондоне совместно с лабораторией Deepmind Health Labs разрабатывают технологии на основе ИИ для повышения точности скрининга на предмет рака молочной железы. Рак молочной железы является наиболее распространенным видом рака среди женщин и ежегодно он диагностируется у 1,6 миллиона женщин.

Новое сотрудничество направлено на достижение точной и ранней диагностики путем понимания того, могут ли инструменты машинного обучения помочь врачам справиться с этими проблемами.

Эти исследования могут активизировать использование вычислительных технологий, которые помогут врачам во всем мире поставить более точный диагноз, что будет способствовать раннему выявлению и быстрому вмешательству, чтобы спасти пациентов при диагностике злокачественных опухолей и выявлении патологии в легких.

В ходе этих исследований разрабатываются компьютерные программы, которые позволяют снизить частоту случаев неточной диагностики раковых опухолей головного мозга, молочной железы, легких и др.

### 1.2.1 Базовая структура нейронной сети

Искусственная нейронная сеть (ИНС), известная как «Нейронная сеть», представляет собой вычислительную модель, основанную на структуре и функциях биологических нейронных сетей. Она похожа на искусственную человеческую нервную систему для приема, обработки и передачи информации с точки зрения вычислительной техники. В принципе, в нейронной сети существуют 3 различных слоя:

- Входной слой (все входы подаются в модель через этот слой). Входной слой взаимодействует с внешней средой, которая представляет собой шаблон для

нейронной сети. Его задача – взаимодействовать со всеми входами. Этот вход передается на скрытые слои, которые объясняются ниже. Входной уровень должен представлять также условие, для которого обучаем нейросеть.

- Скрытые слои (может быть более одного скрытого слоя), которые используются для обработки входов, полученных от входных слоев. Скрытый слой – это коллекция нейронов, к которой применена функция активации, и это промежуточный слой, находящийся между входным и выходным слоем. Его задачей является обработка входов, полученных предыдущим слоем. Таким образом, именно этот слой отвечает за извлечение необходимых функций из входных данных.
- Выходной слой (данные после обработки становятся доступными на выходном слое). Выходной слой нейросети собирает и передает информацию соответствующим образом. Шаблон, представленный выходным слоем, можно напрямую проследить до входного слоя. Количество нейронов в выходном слое должно быть напрямую связано с типом работы, которую выполняла нейросеть. Чтобы определить количество нейронов в выходном слое, сначала рассмотрим предполагаемое использование нейронной сети. В результате связь между входом и выходом может быть описана на рисунке 1.1.

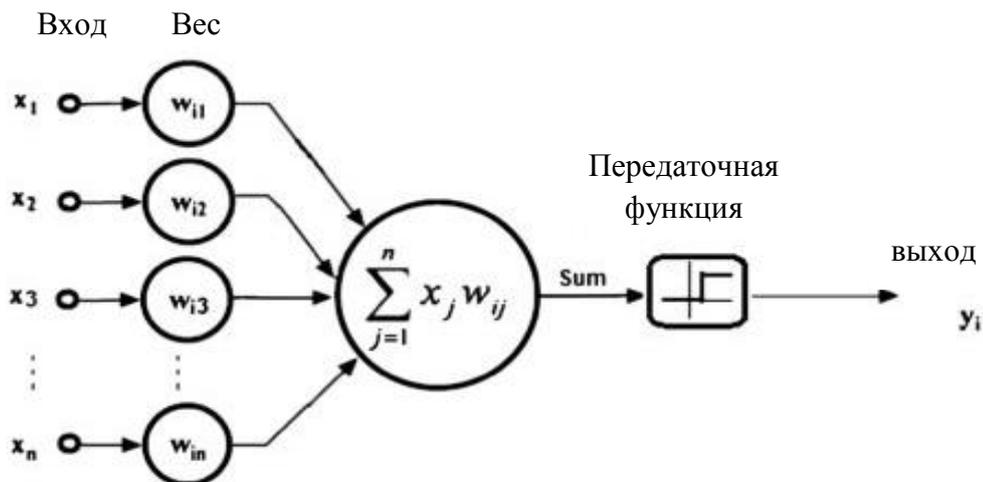


Рисунок 1.1 – Модель нейрона

### 1.2.1.1 Нейронная сеть с прямой связью

Существует несколько различных архитектур нейронных сетей, доступных для приложений медицинской визуализации, но одной из наиболее распространенных является сеть с прямой связью. Обучение в направленных сетях относится к области контролируемого обучения, в которой пары входных и выходных значений подаются в сеть в течение многих циклов, так что сеть «узнает» о взаимосвязи между входными и выходными значениями.

При обратном обучении каждый раз при представлении входного вектора обучающей выборки сравнивается выходной вектор с желаемым значением. На рисунке 1.2 приведена типичная структура сети с прямой связью.

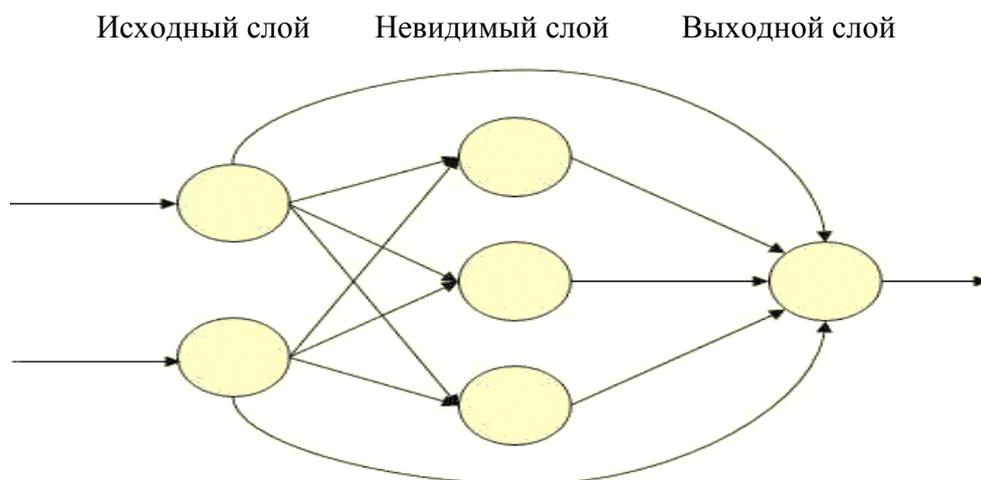


Рисунок 1.2 – Пример сети с прямой связью: с одним скрытым слоем и двумя выходами

Эти соединения являются однонаправленными, что означает, что обрабатываемые сигналы или информация могут проходить через сеть только в одном направлении: от входного уровня через скрытые слои к выходному слою. Основное правило выбора количества выходных узлов зависит от количества различных областей. Рекомендуется использовать одинарную нотацию для представления различных областей, т.е. для каждого выхода только один узел может иметь значение 1. Следовательно, количество выходных узлов = количество различных областей - 1.

В процессе контролируемого обучения предоставляется набор помеченных векторов (вход-мишень) для обучения классификатора, чтобы он мог достичь уровня обобщения и вернуть правильный выход ко всем возможным входным векторам. Напротив, при неконтролируемом обучении предоставляется только набор входных векторов без определения целевого показателя.

Роль алгоритма заключается в том, чтобы найти сходства между входными векторами для группировки похожих входных векторов в один кластер. Обучение с усилением можно рассматривать как сочетание обоих предыдущих типов, где алгоритм определяет, когда вывод неверен, но не описывается, как исправить этот вывод. Алгоритм должен пытаться проверить множество возможностей, пока не выяснит, как получить правильный ответ.

#### 1.2.1.2. Нейронная сеть с обратной связью

Наиболее успешные модели в глубоком обучении в настоящее время основаны на парадигме последовательного изучения представлений, за которым следует уровень принятия решений. Это в основном актуализируется с помощью направляющих многослойных нейронных сетей, таких как ConvNets, где каждый слой формирует одно из таких последовательных представлений. Однако альтернатива для достижения цели использует подход, основанный на обратной связи, при котором представление формируется итеративно в соответствии с обратной связью, полученной от результатов предыдущей итерации.

Прогноз, основанный на обратной связи, определяется как аппроксимация конечного результата итерационным способом, когда операция каждой итерации основана на текущем результате. Обратная связь – это общий способ делать прогнозы в различных областях, начиная от теории управления и заканчивая психологией. В работах [95, 100] установлено, что подход к обучению, основанный на обратной связи, имеет несколько основных преимуществ по сравнению с общепринятой парадигмой обратной связи, что делает его достойной альтернативой. Эти преимущества в основном объясняются тем, что

окончательный прогноз делается эпизодическим, а не одноразовым образом, наряду с прямым представлением о так называемом конечном результате.

### **1.3 Нейронные сети для компьютерной диагностики / обнаружения**

Компьютерное обнаружение для диагностики (CAD) является перспективным направлением исследований в течение последних двух десятилетий. Анализ медицинских изображений направлен на обеспечение более эффективного диагностического и лечебного процесса для рентгенологов и клиницистов. Однако, с развитием науки и техники расшифровка данных вручную в обычных CAD-системах постепенно превратилась в сложную задачу. В качестве инструментов для решения этой задачи успешно используются методы глубокого обучения, особенно конволюционные нейронные сети (ИНС). Можно отметить такие приложения, как диагностика рака молочной железы, обнаружение узлов легких и локализация рака простаты. В нашей работе представлены современные методы анализа медицинских изображений в CAD исследованиях, которые сосредоточены на методах, основанных на использовании конволюционных нейронных сетей (ИНС). Перечислены также широко используемые в литературе базы данных медицинских изображений. Предполагается, что результаты исследований могут предоставить исследователям в области рентгеновских изображений систематическую картину методов на основе ИНС, используемых в CAD системах [21].

CAD-системы широко используются для выявления и диагностики заболеваний при анализе медицинских изображений (рак молочной железы, рак легких, рак простаты, подавление рака костной ткани, поражения кожи и болезнь Альцгеймера). Применение CAD-систем позволяет повысить точность диагностики, сократить временные затраты и оптимизировать нагрузку на рентгенологов [32, 134]. Глубокое обучение – это новая методология, которая превосходит традиционные машинные методы обучения и все шире используется в CAD [124]. Как правило, при машинном обучении функции извлекаются вручную, в то время как при глубоком обучении это полностью

автоматический процесс. Кроме того, в процессе машинного обучения можно получить такие простые свойства, как цвета, края и текстуры, в то время как в процессе глубокого обучения в процессе обучения доступны некоторые иерархические или композиционные особенности.

### 1.3.1. Обнаружение и диагностика объекта (онкологии молочной железы)

Машинное обучение (ML) стало важной частью исследований в области медицинской визуализации. Методы ML эволюционировали на протяжении многих лет от ручного ввода до автоматической инициализации. Достижения в области ML привели к созданию более интеллектуальных и самодостаточных систем компьютерной диагностики (CAD), так как обучаемость методов ML постоянно совершенствуется.

Появляется все больше автоматизированных методов с глубоким изучением особенностей и представлений. Последние достижения ML с более глубокими и обширными представлениями, известными как подходы глубокого обучения (DL), оказали существенное влияние на улучшение диагностических возможностей CAD-систем [110].

Ge и др. [45] разработали автоматизированную систему обнаружения для автоматической идентификации кластеров микрокальцификации на цифровых маммограммах. Логистическая сигмоидная функция выбрана в качестве передаточной функции, как для скрытых нейронов, так и для выходных нейронов. Иллюстрация структуры нейронной сети и ее внутренних связей между входным слоем, скрытым слоем и выходным слоем приведена на рисунке 1.3.

Ядра свертки организованы таким образом, чтобы подчеркнуть ряд характеристик изображения, а не менее коррелированные значения, полученные из пространственных объектов для ввода. Эти характеристики включают в себя: а) горизонтальная и вертикальная информация; б) локальная и нелокальная информация; в) обработка (фильтрация) изображения и распространение сигнала

[95].

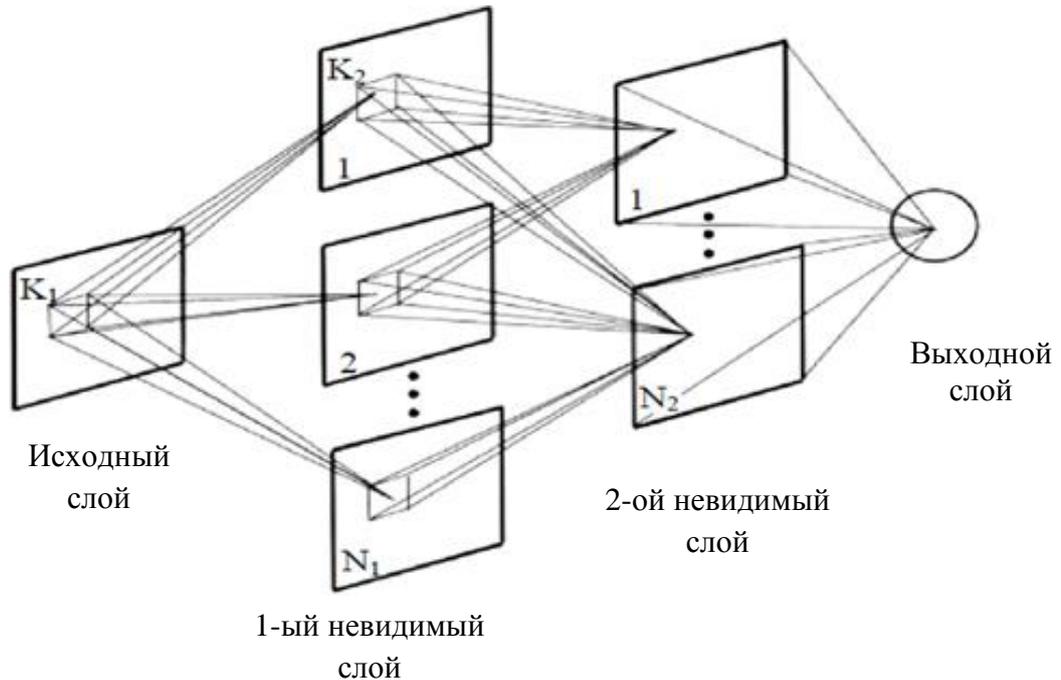


Рисунок 1.3 – Принципиальная схема алгоритма ИНС

Всего 25 признаков (21 морфологических признаков плюс 4 особенности ИНС) были извлечены для каждого кластера. Затем для дифференциации кластерных микрокальцификаций от ложных срабатываний использовали классификатор линейного дискриминационного анализа. Выбор функции – линейный дискриминантный анализ (ЛДА) включает в себя выбор трех параметров.

Чтобы разработать компьютеризированную схему обнаружения кластерных микрокальцификаций на маммограммах, Nagel и др. [103] рассмотрели три метода анализа признаков: основанных на правилах (используемый в настоящее время метод) искусственной нейронной сети (ИНС) и комбинированный метод.

Вышеупомянутые приложения охватывают различные аспекты применения нейронных сетей, такие как количество нейронов в скрытом слое, сокращение функций в классификациях, сокращение соединений для повышения эффективности. Подобные улучшения могут быть сделаны при применении ИНС для других практических приложений, а не только при идентификации кластеров микрокальцификации. Что касается других подходов, а не только

применения ИНС в обнаружении и классификации при анализе маммограмм, можно обратиться к статьям [30, 123].

Представляем недавние работы по обнаружению рака молочной железы с использованием традиционных методов машинного обучения (ML) и глубокого обучения (DL). Целью работы является предоставление введения в литературу по анализу данных и последние достижения в диагностике рака молочной железы, используя многоракурсные цифровые маммограммы (DMS).

Цель обзора состоит в том, чтобы осветить проблемы, связанные с применением DL для раннего выявления рака молочной железы с использованием многоракурсных цифровых маммографических данных. Представляем недавние исследования, направленные на решение этих задач, и, наконец, предлагаем некоторые соображения и обсуждения по актуальным открытым проблемам.

Данный обзор разделен на две основные части. В первой части представлено краткое введение различных этапов традиционного маммографического метода исследования молочной железы (усовершенствование, выделение признаков, сегментация и классификация). Во второй – основное внимание уделено методам цифровой маммографии с акцентом на многоракурсные (CC и MLO) маммографические данные. Настоящую литературу по DL можно охарактеризовать с точки зрения методов дискриминации, выявления и классификации поражения при раке молочной железы в многоракурсных цифровых маммографических данных.

### 1.3.2. Обнаружение и диагностика локального объекта (патологий в легких)

Являясь наиболее распространенным средством обследования в медицинской практике, рентгенограмма грудной клетки имеет важное клиническое значение для диагностики заболевания. Таким образом, автоматическое выявление заболевания грудной клетки на основе

рентгенографии грудной клетки стало одной из актуальных тем в исследованиях, связанных с медицинской визуализацией.

Основываясь на клинических приложениях, исследователь проводит комплексное обследование с использованием систем автоматизированного обнаружения (CAD), уделяя особое внимание технологиям искусственного интеллекта, применяемым в рентгенографии грудной клетки.

В работе [154] авторы разработали систему автоматизированной диагностики, основанную на двухуровневой архитектуре искусственных нейронных сетей (ИНС). Она была обучена, протестирована и оценена специально по проблеме обнаружения узлов рака легких, обнаруженных на оцифрованных рентгенограммах грудной клетки.

Первая ИНС выполняет обнаружение подозрительных областей на снимке низкого разрешения. Входом во вторую ИНС являются пики кривизны, рассчитанные для всех пикселей в каждой подозрительной области. Это связано с тем, что небольшие опухоли имеют и идентифицируемые сигнатуры в пространстве пик кривизны, где кривизна – это локальная кривизна данных изображения при просмотре в виде карты рельефа. Выход этой сети пороговый на выбранном уровне значимости, чтобы дать положительное обнаружение. Испытания проводятся с использованием 60 рентгенограмм, взятых из обычной клиники, с 90 реальными узлами и 288 смоделированными узлами.

В работе [149] предложили процедуру автоматической диагностики под названием «Обнаружение на основе нейронного ансамбля», в которой используется ансамбль ИНС для идентификации клеток рака легкого на образцах биоптатов игл, полученных из объектов, подлежащих диагностике.

Keserci B. и др. [73] разработали компьютерную схему диагностики для автоматического обнаружения узелков легкого в цифровых рентгенограммах грудной клетки на основе комбинации морфологических признаков и вейвлет-преобразования. В их схеме метод ИНС использовался для эффективного уменьшения ложных срабатываний с использованием комбинированных функций.

Рентгенограмма грудной клетки (СХР) – это экономичная и простая в использовании медицинская техника визуализации и диагностики. Эта методика является наиболее часто используемым диагностическим инструментом в медицинской практике и играет важную роль в диагностике заболевания легких [37]. Хорошо обученные рентгенологи используют рентгенограмму грудной клетки для выявления таких заболеваний, как пневмония, туберкулез, интерстициальная болезнь легких и ранний рак легких.

Рентгенограмма грудной клетки является наиболее распространенным методом визуализации при легочных заболеваниях. Благодаря повсеместному использованию, существует обширная литература, посвященная автоматическому выявлению сердечно-лёгочных заболеваний в цифровых рентгеновских снимках грудной клетки (СХР). Одним из важных шагов для автоматизированного анализа СХР является локализация соответствующей области интереса, выделение легочной области от других, менее значимых частей, для применения алгоритмов принятия решений.

CAD-системы в основном разделены на следующие этапы: предварительная обработка изображений; извлечение областей интереса; извлечение признаков и классификация заболеваний по признакам. Недавнее развитие искусственного интеллекта (ИИ) в сочетании с накоплением больших объемов медицинских изображений открывает новые возможности для построения CAD-систем в медицинских приложениях.

Методы искусственного интеллекта (включая поверхностное и глубокое обучение и т.д.), в основном заменяют процесс извлечения признаков и классификации заболеваний в традиционных CAD-системах. Методы искусственного интеллекта также широко используются при сегментации изображений при рентгенографии грудной клетки. Данное исследование представляет собой обзор современной литературы по обнаружению границ легких на СХР изображениях.

### 1.3.3. Обнаружение и диагностика объекта на МРТ снимках (опухоли головного мозга)

Выявление, сегментация и обнаружение области патологии на изображениях МРТ (опухоли головного мозга) является трудоемкой задачей. Различная анатомическая структура может быть визуализирована с помощью концепции обработки изображений. Сложно получить представление об аномальных структурах мозга с помощью простых методов визуализации. Магнитно-резонансная томография различает и уточняет нейронную архитектуру человеческого мозга. МРТ-техника содержит множество методов визуализации, которые сканируют и захватывают внутреннюю структуру человеческого мозга.

Метод ИНС также широко применяется при диагностике заболеваний на МРТ изображениях. В работе Guo D. и др. [48] предложена компьютерная диагностическая система для классификации поражений печени крыс с помощью МРТ снимков.

По данным Всемирной организации здравоохранения шкалы системы оценок используются с I по IV классы. Эти классы классифицируют доброкачественные и злокачественные типы опухолей. Классы I и II – опухоли низкого уровня, в то время как классы III и IV – определяют опухоли высокого уровня. Опухоль мозга может поражать людей в любом возрасте. Влияние на каждого человека может быть неодинаковым. Из-за сложной структуры человеческого мозга диагностика опухолевой области в головном мозге является сложной задачей.

Злокачественный тип III и IV классов опухоли быстро растет. Поражает здоровые клетки головного мозга и может распространиться на другие участки мозга или спинного мозга, является более опасной и может остаться незамеченной. Поэтому выявление таких опухолей головного мозга, их идентификация и классификация на более ранней стадии является серьезной проблемой в медицинской науке. Совершенствование новых методов визуализации помогает врачам наблюдать и отслеживать возникновение и рост

пораженных опухолью участков на разных стадиях, чтобы с помощью сканирования изображений можно было поставить правильный диагноз.

ИНС использовалась для оценки работы рентгенологов по дифференциальной диагностике внутриосевой опухоли головного мозга в изображениях МРТ. В работе Jiang J. и др. [68] для дифференциации 4 категорий опухолей использовалась трехслойная сеть с прямой ИНС-связью в сочетании с алгоритмом Левенберга-Марквардта, а также с использованием 2 клинических параметров и 13 рентгенологических показателей в изображениях МРТ.

Döhler F. и др. [41] предложили клеточную ИНС для выявления склероза гиппокампа при МРТ сканировании. Используя базу данных, которая состояла из большого количества объектов интереса, извлеченных из T1-взвешенных магнитно-резонансных изображений от 144 субъектов, авторы продемонстрировали, что сеть позволяет классифицировать ткани мозга по наличию или отсутствию мезиального височного склероза.

Сегментация была использована для определения пораженной части опухоли с помощью методов визуализации. Сегментация – это процесс разделения изображения на составляющие его части, обладающие одинаковыми свойствами, такими как цвет, текстура, контраст и границы.

#### **1.4. Извлечение информативных признаков**

Классификация медицинских изображений является ключевым методом систем автоматизированной диагностики (CAD). Традиционные методы опираются, главным образом, на форму, цвет и/или особенности текстуры, а также на их комбинации, большинство из которых специфичны для конкретной проблемы. Которые также показали взаимодополняемость в медицинских образах, что приводит к созданию систем, которые способны делать представления о высокоуровневых концепциях проблемной области и имеют способность к обобщению моделей. Современные методы глубокого обучения обеспечивают более эффективный способ построения сквозной модели, которая может вычислять окончательные классификационные метки с необработанными

пикселями медицинских изображений [46, 53].

Классификация гистопатологических изображений и идентификация раковых областей достаточно сложна из-за сложности фона изображения и его разрешения. Разница между нормальной тканью и раковой тканью в некоторых случаях очень мала [106]. Поэтому особенности тканевых пятен на изображении имеют ключевое значение для автоматической классификации. Использование только одной функции или нескольких функций приводит к неудовлетворительным результатам классификации из-за небольшой разницы между текстурами.

В работе [102] предложен метод обнаружения скрытых данных, основанный на извлечении признаков из вейвлет-домена Маркова, гистограммы и функции когерентности по сравнению с существующими признаками (72 DWT). Наконец, использовался BP классификатор, чтобы отличить изображение с патологией от изображения без патологии. В работе [34] предложен метод анализа аномалий, основанный на извлечении признаков в виде марковских признаков, калиброванных и комбинированных признаков модифицированных. Затем они использовали (SVM) и (MLP) классификаторы для классификации изображений на две группы (нормальную и ненормальную).

В работе [5] авторы предложили метод стеганографии изображений для вставки определенного сообщения либо в пространственную область, либо в область преобразования изображения на основе целочисленного вейвлет-преобразования (IWT). Предлагаемый метод сочетает в себе преимущества обнаружения кромок и кодирования XOR. Результаты экспериментов показали, что предложенный метод превосходит многие известные методы стеганографии изображений.

Одна из стратегий комплексной обработки данных является классификация. Как правило, блок-схема алгоритма классификации локального объекта на изображении (опухоли) включает следующие фазы, как показано на рисунке 1.4 [91]:

- ✓ Извлечение признаков.

## ✓ Классификация.

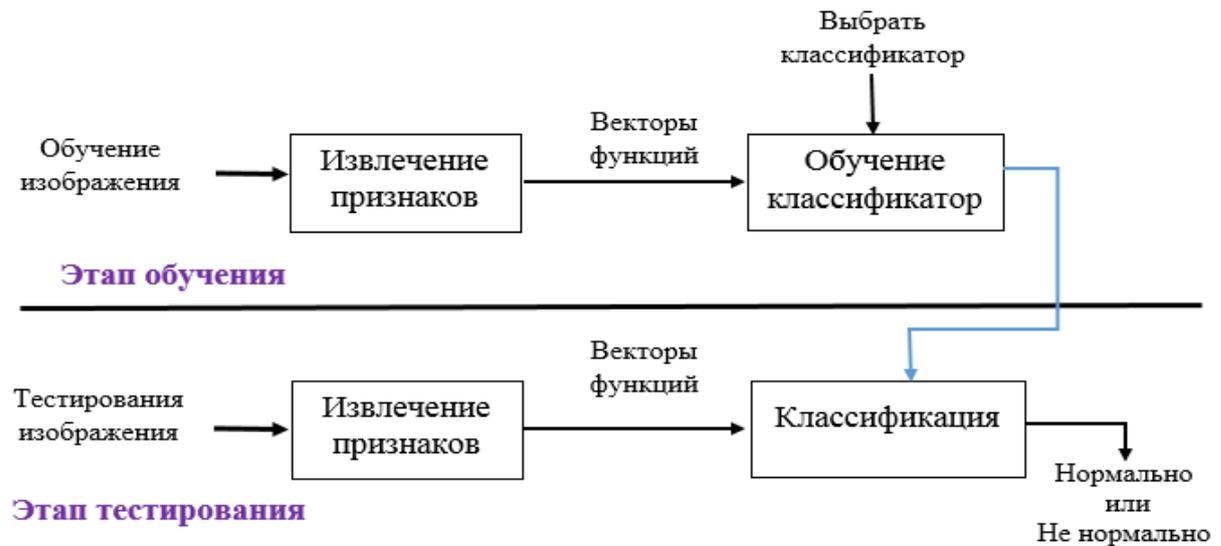


Рисунок 1.4 – Общая блок-схема системы классификации

В процессе извлечения элементов изображения из него выделяется группа уникальных статистических атрибутов. Эти атрибуты также называются особенностями. Процесс извлечения элемента контура можно рассматривать как процесс уменьшения размерности. Извлеченные атрибуты или функции должны быть чувствительны к вставляемым сообщениям. Некоторые из функций, которые могут быть использованы, включают метрики качества изображения, моменты статистических гистограмм изображения, вейвлет-декомпозиции и матрицы маркова – эмпирической матрицы перехода.

В процессе обучения или тренировки выделяется набор обозначенных векторов обучения, который включает в себя значения выделенных элементов в качестве входных данных для классификатора. После завершения процесса обучения классификатор сможет предсказать, какой класс имеет тот или иной классификационный вектор.

## 1.4.1. Дискретное вейвлет-преобразование (DWT)

Вейвлет использовался для анализа различных изображения в частотной области при разных масштабах. Здесь используем дискретное вейвлет-преобразование (DWT), которое является мощным инструментом для

извлечения функций. В частности, метод использован для извлечения коэффициентов вейвлет-преобразования при анализе изображений МРТ мозга. Вейвлет локализует частотную информацию о сигнальной функции, которая важна для классификации. Применено дискретное 2D вейвлет-преобразование, в результате которого получены четыре подполосы LL (низко), HL (высоко низко), LH (низко высоко), HH (высоко) с двухуровневым вейвлетным разложением области интереса (ROI).

При 2D-уровневом разложении изображения отображается аппроксимация с подробными тремя изображениями, представляющими низкочастотное и высокочастотное содержимое изображения, соответственно, [5, 102]. Вейвлет-аппроксимации на первом и втором уровнях представлены, соответственно, LL1, LL2. Они представляют собой низкочастотную часть изображений. Высокочастотная часть изображений представлена изображениями LH1, HL1, HH1, HH1, LH2, HL2, HL2 и HH2, которые дают детальное представление о горизонтальном, вертикальном и диагональном направлениях на первом и втором уровнях, соответственно.

Мы использовали низкоуровневое изображение, где LL1 представляет собой аппроксимацию исходного изображения, а далее разлагается на приближение второго уровня и детали изображения. Этот процесс повторялся до тех пор, пока не достигаем желаемого уровня разрешения.

С помощью 2D дискретного вейвлет-преобразования изображения были разложены на пространственно-частотные компоненты, а так как HL-подполосы имеют более высокую значимость по сравнению с LL, использовали как LL, так и HL для лучшего анализа, описывающего особенности изображения [91]. Различные частотные составляющие и каждая составляющая изучались с разрешением, соответствующим ее масштабу, и выраженным следующим образом:

$$DWT_{p(s)} = \begin{cases} di, j = \sum p(s)h * i(s - 2ij) \\ di, j = \sum p(s)g * i(s - 2ij) \end{cases} \quad (1.1)$$

Коэффициенты  $d_{i,j}$  относятся к атрибуту компонента в сигнале  $p(s)$ , соответствующему функции вейвлета, в то время как  $b_{i,j}$  относятся к приближенным компонентам в сигнале. Функции  $h(s)$  и  $g(s)$  в уравнении представляют собой коэффициенты фильтра высоких и низких частот, соответственно, а параметры  $i$  и  $j$  относятся к шкале масштабов вейвлетов и коэффициентам смещения, соответственно.

#### 1.4.2. Матрица когерентности серого уровня (GLCM)

Матрица Gray Level Co-Occurrence Matrix (GLCM) – это надежный способ статистического анализа изображений. Используется нами для оценки характеристик изображений относительно статистики второго порядка, рассматривая связь между двумя соседними пикселями в одном смещении в качестве текстуры второго порядка.

По умолчанию GLCM определяется путем вычисления количества пикселей серого цвета, которые находятся горизонтально рядом с пикселями, имеющими уровень серого  $j$ . Первый пиксель называется опорным пикселем, а второй пиксель – пикселем соседнего цвета. Однако, можем определить другие пространственные соотношения пикселей, используя различные значения для параметра "offset".

По умолчанию значение смещения равно  $[0 \ 1]$ , где первое значение соответствует количеству строк между опорным и соседним пикселями, а второе – количеству столбцов между опорным и соседним пикселями. Кроме того, GLCM обычно известна как двумерная матрица вероятностей соединения между парами пикселей [17, 56]. На рисунке 1.5 приведен пример того, как матрица GLCM вычисляет значения GLCM (1, 1).

Видно, что в матрице это положение содержит значение 1, поскольку изображение содержит только один случай, когда оба смежных по горизонтали пикселя имеют значение 1. И, как видно из рисунка 1.5, расположение GLCM (1, 2) содержит значение 2, поскольку на рисунке есть два случая, когда соседние по

горизонтали пиксели имеют значения 1 и 2.

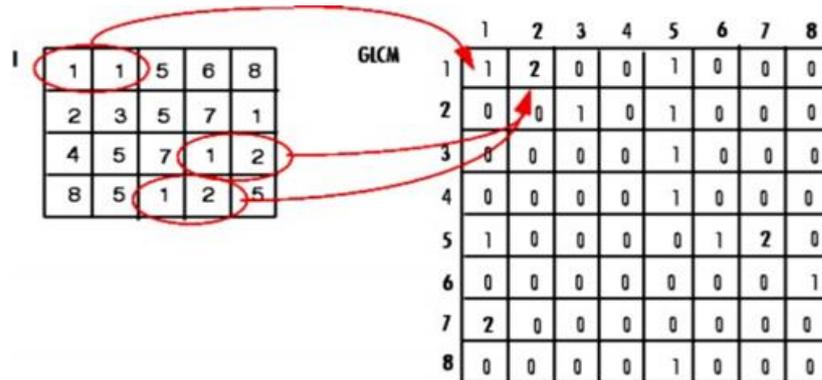


Рисунок 1.5 – Пример, показывающий, как построена схема GLCM

Матрица повторяемости представляет собой статистическую модель, которая позволяет использовать ее в различных областях анализа изображений, например, в биомедицине и т.д. [77, 101]. Из матрицы GLCM можно извлечь множество различных статистических характеристик (18 характеристик), таких как энергия, энтропия, дисперсия и т.д. Эти особенности рассчитываются на основе группы статистических данных второго порядка [5].

### 1.5. Алгоритмы обнаружения контуров

Обнаружение контуров является основополагающим инструментом в обработке изображений, особенно в областях обнаружения и извлечения элементов изображения, целью которого является идентификация точек на цифровом изображении, на которых изображение имеет прерывистость [73]. Стоит также упомянуть классические работы по обработке медицинских изображений [8, 144]. Так для обнаружения опухоли используются изображения компьютерной томографии (КТ) или магнитно-резонансной томографии (МРТ). Соответствующее медицинское оборудование этих типов производит заметную долю шума на полученных изображениях.

Существующие методы выявления и оценки локальных объектов интереса (опухолей) подразделяются на локальные и контурные методы. Методы, основанные на данных локальной области [38, 70] направлены на поиск групп пикселей, которые имеют некоторое сходство. Контурные методы [124, 161] основаны на эволюции кривой, основанной на внутренних и внешних

показателях, таких как градиент изображения для разграничения границ исследуемых структур (например, опухоли головного мозга, молочной железы и другие патологии).

Многие исследователи используют широкий спектр методов, основанных на сегментации, для решения задачи локализации и анализа характеристик объектов (опухоли). В работе [144] выполнена сегментация медицинских изображений на основе морфологических операторов наряду с выбором порога. Джэйн и др. также использовали морфологические операции наряду с пороговой и «водораздельной» сегментацией [130].

Кроме того, для сегментации изображений часто используется метод кластеризации – нечеткие С-средние (FCM) [108, 161]. В работе [144] предложили гибридный подход, который представляет собой сочетание «водораздельного» метода обнаружения Кэнни для определения границ опухоли на снимке МРТ (для различных случаев опухолей головного мозга и молочной железы).

Существуют также методы, использующие сдвиговое (шиарлет) преобразование. Один из них при медицинской обработке изображений использует цветовое кодирование для представления контуров [28]. Достаточно эффективные методы решения этой задачи и визуализации изображений для диагностики и морфологического анализа представлены в работе [145]. Количественный морфологический анализ аналогичного типа проводится при решении актуальных клинических экспериментальных задач в области пластической хирургии [112].

Одной из основных составляющих анализа медицинских изображений является оценка объекта на основе построения контура. Контур объекта можно описать по краю, который при цифровой обработке изображения определяется как переход между двумя областями с существенно разными уровнями интенсивности. Большинство методов обнаружения краев используют локальные операторы, основанные на дискретных приближениях первой и второй производных серого уровня изображения.

### 1.5.1. Обнаружение контуров изображения на основе улучшенного оператора Кэнни

Оператор Кэнни представляет собой многомасштабный алгоритм обнаружения краёв, предложенный Джоном Ф. Кэнни в 1986 году. Алгоритм сначала использует фильтр Гаусса для сглаживания изображения, затем рассчитывает амплитуду и направление градиента сглаженного изображения, а также выполняет максимальное подавление, наконец, обнаруживает и соединяет края [81, 158].

Однако традиционный оператор Кэнни извлекает только градиенты направления  $x$  и  $y$  в окрестностях  $2 \times 2$ . Этот метод теряет некоторую важную информацию о краях в направлении наклона ( $45^\circ$  и  $135^\circ$ ). Для решения этой задачи мы используем метод расчета исходной информации о градиенте и информации о направлении наклона для определения величины градиента пикселя. Этот метод учитывает как точность определения местоположения, так и помехоустойчивость.

Для каждого пикселя  $(i, j)$  частичные производные по  $X$ ,  $Y$  для  $45^\circ$  и  $135^\circ$  представлены следующим образом:

$$\begin{aligned} P_x(i, j) &= I(i + 1, j) - I(i - 1, j), \\ P_y(i, j) &= I(i, j + 1) - I(i, j - 1), \\ P_{45^\circ}(i, j) &= I(i - 1, j + 1) - I(i + 1, j - 1), \\ P_{135^\circ}(i, j) &= I(i - 1, j + 1) - I(i + 1, j - 1). \end{aligned} \quad (1.2)$$

Величина градиента:

$$G(i, j) = \sqrt{P_x^2(i, j) + P_y^2(i, j) + P_{45^\circ}^2(i, j) + P_{135^\circ}^2(i, j)}. \quad (1.3)$$

Направление градиента:

$$\theta(i, j) = \arctan\left(\frac{P_x(i, j)}{P_y(i, j)}\right). \quad (1.4)$$

При использовании оператора Кэнни для распознавания кромок выбор верхнего и нижнего порога также важен, что напрямую определяет количество

информации о кромке. Начальная точка края обычно определяется высоким порогом. Чем меньше высокий порог, тем больше информации о зарезервированных краях, но псевдо-краев также будет больше. Напротив, чем выше порог, тем более эффективным будет порог, но можем потерять некоторую важную информацию о крае.

Для получения более полной информации, исходя из [78, 120], в качестве стандартного отклонения средней амплитуды градиента  $m$  всего изображения и стандартного отклонения  $d$  амплитуды градиента всех пикселей на изображении берем среднюю амплитуду градиента  $m$  в качестве высоких пороговых параметров. Высокий порог определяется следующим образом:

$$T_h = m + k \times d, \quad (1.5)$$

$$m = \frac{1}{I_x \times I_y} \sum_{i=0}^{I_x} \sum_{j=0}^{I_y} G(i, j), \quad (1.6)$$

$$d = \frac{1}{I_x \times I_y} \sqrt{\sum_{i=0}^{I_x} \sum_{j=0}^{I_y} (G(i, j) - m)^2}, \quad (1.7)$$

где  $I_x \times I_y$  – общее количество пикселей;  $G(i, j)$  – градиент пикселей;  $k$  – параметр настройки, в основном для того, чтобы избежать прямого добавления  $m$  и  $d$ , что приведет к потере некоторых деталей края изображения. Эксперименты показывают, что при  $k \in (0.5, 0.7)$  эффект определения границ является почти идеальным. Для того чтобы уменьшить трудоемкость расчета нижний порог принимается равным:  $T_l = 0.4 \times T_h$ .

Следующие примеры являются результатом обработки урологического изображения. На рисунке 1.6 показан контур, выделенный этим подходом.

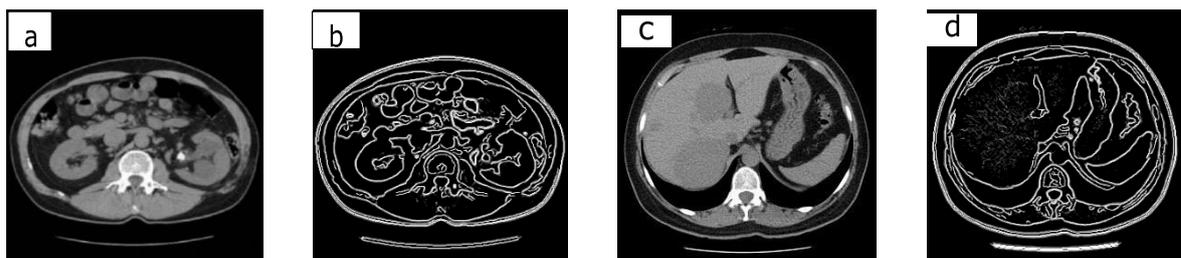


Рисунок 1.6 – Пример определения границ. а) и с) оригиналы; б) и d) контуры объектов, полученные указанным выше алгоритмом

Преобразование сдвига (шиарлет) также позволяет получить карту контуров интересующего объекта с большей точностью (в среднем на 3-8%).

Для дальнейшего объективного анализа влияния алгоритмов обнаружения краев мы принимаем непрерывное соотношение пикселей краев ( $R$ ) для анализа эффективности каждого метода обнаружения. Показатель  $R$  определяется следующим образом:

$$R = \frac{CEN}{TEN}, \quad (1.8)$$

где  $CEN$  – представляет общее количество последовательных краевых пикселей граничного изображения;  $TEN$  – представляет общее количество пикселей граничного изображения. Чем больше  $R$ , тем лучше непрерывность края и изображение края.

В таблицах 1.1 и 1.2 использовали  $R$  в качестве показателя объективной оценки. Чем больше  $R$ , тем лучше непрерывность краев изображений. Мы рассчитали значения  $R$  изображения края на рисунке 1.7 и результаты приведены в таблицах 1.1 и 1.2. Данные показывают, что непрерывность ребер нашего метода сдвига лучше, чем показывают другие алгоритмы.

Таблица 1.1 – Результат определения (рис. 1.7, b).

	Собела	Канни	Вейвлет	Шеарлет	Разработанный метод
<b>CEN</b>	10496	18360	36142	21850	31280
<b>TEN</b>	13580	36582	41952	25998	33940
<b>R</b>	0,7729	0,5018	0,8615	0,8404	0,9216

Таблица 1.2 – Результат определения (рис. 1.7, d).

	Собела	Канни	Вейвлет	Шиарлет	Разработанный метод
<b>CEN</b>	93860	13924	14197	12848	21794
<b>TEN</b>	11088	16362	16001	14078	22943
<b>R</b>	0,8465	0,8509	0,8872	0,9126	0,9499

## 1.6. Выводы по первой главе

Анализ медицинских изображений для исследований локальных объектов (опухолей) в последнее время привлекает внимание из-за возросшей потребности в эффективной и объективной оценке больших объемов данных. Хотя инновационные подходы к применению автоматизированных методов анализа изображений локальных объектов (опухоли головного мозга, молочной железы и др., а также патологии легких) насчитывают почти два десятилетия, современные методы становятся все более адекватными и применяются для клинической диагностики.

Получены следующие результаты.

1. Представлено описание современных подходов и алгоритмов для обработки и анализа визуальных данных применительно к МРТ, КТ и СХР изображениям, которые содержат области с патологией.
2. Представлено описание современного состояния в области разработки алгоритмов сегментации, распознавания, классификации и моделирования данных, связанных с изображениями объектов интереса.
3. Опыт практического применения существующих зарубежных и отечественных программных систем, реализующих методы интеллектуального анализа данных для решения задач клинической диагностики, демонстрирует полезность применения этих методов для повышения уровня информатизации клинической работы врачей.
4. В настоящее время основная медицинская информация о пациентах (социально-демографические сведения и клинические данные) аккумулируется в виде электронных медицинских карт, хранимых в базах данных медицинских информационных систем. Анализ медицинских данных значительно осложняется их многомерностью и разнотипностью.
5. Обсуждаются качества различных подходов с упором на методы, которые можно применять к стандартным протоколам клинической визуализации. В итоге, предложен алгоритм обнаружения границ интересующего объекта

на основе методики детектора Кэнни. Экспериментальные результаты анализа изображений показывают, что по сравнению с традиционными и существующими методами обнаружения контуров, этот метод имеет лучший эффект обнаружения контуров с точной локализацией кромок, непрерывных и полных кромок, а также их деталей. Это практичный и эффективный метод обнаружения границ, как показано в таблицах 1.1 и 1.2.

## **ГЛАВА 2. АЛГОРИТМЫ СЕГМЕНТАЦИИ И КЛАССИФИКАЦИИ ЛОКАЛЬНЫХ ОБЛАСТЕЙ НА ИЗОБРАЖЕНИЯХ (МРТ И КТ)**

Исследования в этой главе посвящены разработке метода сегментации объектов и алгоритма классификации (на примере опухолей) МРТ-изображений на основе использования разработанных вычислительных процедур. Исследуются алгоритмы пороговой итеративной сегментации объектов на изображениях МРТ. Известно, что весьма сложно выбрать подходящий глобальный порог для получения идеального начального контура из-за различий в уровнях серого в области патологии на снимках (на пример, опухоли мозга и молочной железы), а также для неинфицированной области, учитывая высокую корреляцию между соседними участками последовательных изображений (МРТ и КТ).

Обнаружение и классификация краев объектов интереса (опухоли головного мозга или молочной железы) на МРТ медицинских изображениях помогает врачам во время постановки диагноза. С помощью сегментации можно с высокой степенью точности определить область (контур) этих областей (опухолей и нормальных областей головного мозга и молочной железы). Показано, что полученные результаты точны и адекватны, поскольку существует множество методов, но выбраны методы, обеспечивающие наилучшие результаты.

### **2.1. Методы обработки и анализа локальных областей на изображениях**

Большинство клиник используют цифровые технологии для поддержки принятия решений в своей работе. Результаты диагностики основаны, как правило, на медицинском изображении, специалисты врачи часто используют изображение для выявления медицинских проблем у пациентов. Основываясь на информации, полученной с изображения, особенно на границах объекта, врачи разрабатывают соответствующий план лечения. В тоже время, часто возникают проблемы из-за неточности в диагнозе, которая связана с отсутствием

информации на изображении, так как изображение не было эффективно обработано.

Поэтому для точной диагностики необходимо получить больше информации с помощью вычислительных технологий. Детектирование краев и распознавание образов является одним из важных первичных инструментов обработки изображений, особенно в области обнаружения и извлечения объектов интереса, целью которого является идентификация точек на цифровом изображении, от которых зависит изображение [21].

Существуют многочисленные исследования в данной предметной области [95, 148], а также применение магнитно-резонансной томографии [71], извлечение участков белой мозговой ткани и одноклеточное детектирование [85], топологическая визуализация пролиферации мозга человека с помощью МРТ [116]. Известно, что фракционирование является важным, но сложным этапом в классификации и анализе медицинских визуальных данных.

Извлечение локального объекта (опухоли мозга) требует разделения изображений МРТ на две области [4]. В одной области находятся локальный изучаемый объект (клетки опухоли головного мозга), вторая область – нормальные клетки [1]. В работе [124] были предложены нечеткие средства кластеризации (FCM), часто используемые для сегментации изображений. В [159] предложен метод разделения на две области (опухоль головного мозга), основанный на гибридном подходе.

В этой задаче важной характеристикой является коэффициент сходства для измерения сегментированного серого и белого веществ на основе МРТ изображений. Для решения задачи анализа изображений – распределение линейных и нелинейных признаков (ребер, границ, атрибутов объекта) могут быть использованы такие методы как Собель, Прюитт, Робертс, Кэнни и Лог [26, 130], а также преобразование сдвига [80].

Современные методы идентификации и оценки локальных областей (опухолей) подразделяются на пространственные и контурные. Пространственные методы [118, 147] определяют группы пикселей, имеющих

некоторое сходство. Эти методы освобождают от некоторых вычислительных операций врача-рентгенолога за счет автоматизации определенных аспектов применения низкоуровневых операций, таких как выбор порога, анализ графа, классификация.

Известно, что раннее выявление опухоли (например, молочной железы) с последующим соответствующим лечением может снизить риски [7]. Осознание того, что эта опухоль является разновидностью онкологической опухоли, играет важную роль в принятии врачами решений о применении адекватных методов лечения и, таким образом, о восстановлении здоровья людей [31, 141].

В работе [72] определение типа опухоли является сложной задачей, поскольку некоторые из характеристик опухолей – кластеризованные, изолированные протоки с плохо определенной массой и т.д. не достаточно хорошо идентифицируются из-за низкой контрастности и неоднозначности границ опухолей на ультразвуковых изображениях.

В работе [94] авторы предложили новую вычислительную основу для выявления и сегментирования объектов (опухоль молочной железы) на ультразвуковых изображениях. В работе [128] предлагается метод, включающий обнаружение локального объекта (опухоль молочной железы) путем сегментации изображений маммографии на основе простых методов обработки изображений, которые дают хорошие результаты в режиме реального времени.

В частности, в работе [39] используется вейвлет-преобразование и метод К-кластеризации для сегментации онкологической опухоли на маммографических изображениях. Затем алгоритм К-среднее применяется к контрастированному изображению, в котором опухолевая область может быть определена методом порогового разделения.

Авторы работы [13] применили усиленный подход, основанный на двойном пороговом значении для сегментации изображений маммографии. Также добавили границы конечного сегментированного изображения в качестве контура к исходному изображению, помогая врачам обнаружить опухоль молочной железы на различного качества маммограммах.

Обнаружение опухолей молочной железы на маммограмме с использованием конволюционной нейронной сети (машинное обучение) может помочь медицинским работникам диагностировать заболевание с большей точностью. Глубокое обучение или нейронные сети являются одним из методов, который может быть использован для классификации объектов интереса (нормальной и аномальной) для решения задачи диагностики [43, 139].

Эта потребность в заключении и диагностике, включая одновременное рассмотрение информации, поступающей из различных источников, является необходимым предварительным условием для детального анализа медицинских изображений. В диссертации рассмотрены различные методы автоматического анализа полученных изображений объектов интереса (опухоли головного мозга и молочной железы).

## **2.2. Алгоритмическая процедура сегментации и классификации локальных областей (опухолей) на изображениях**

Результат обработки определяется качеством изображений, полученных с помощью медицинских приборов. В большинстве случаев полученные изображения (или наборы изображений) имеют заметные шумы, вызванные технологическими особенностями работы устройств.

Существует множество методов, используемых при обнаружении опухолей головного мозга и опухолей молочной железы или их сегментации в различных системах. Предлагаемая нами алгоритмическая процедура работает над сегментацией объектов (опухолей головного мозга и молочной железы) с высокой точностью и их классификацией. Поскольку результаты анализа медицинских изображений могут быть искажены из-за присутствия шума на изображениях, для повышения точности диагностики на изображениях МРТ предлагаем использовать следующий алгоритм обработки локальных объектов (опухолей) на МРТ снимках, как показано на рисунке 2.1.

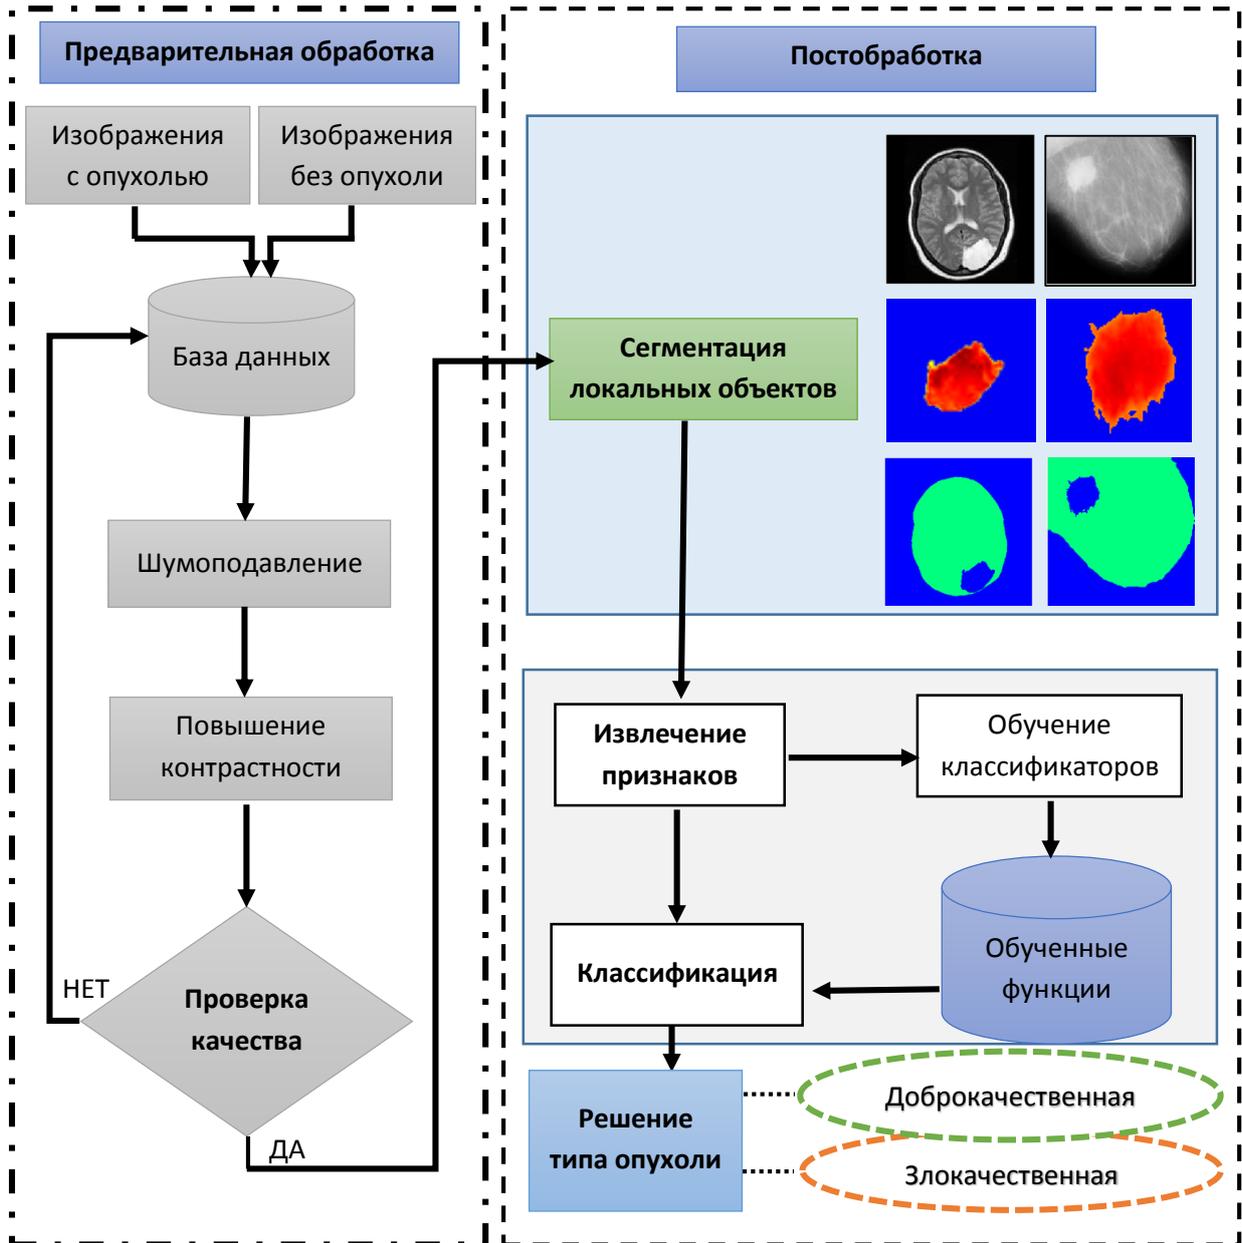


Рисунок 2.1 – Блок-схема классификации локальных объектов (опухолей) для анализа медицинских изображений МРТ (мозга и молочной железы)

Для определения типа опухоли у пациента врачи обычно обращаются к изображению и составляют отчет об анализе изображения. Предложенный нами метод поможет врачу в диагностике для онкологических больных, а также врач может обучить систему на основе некоторых известных данных, а затем использовать эту систему для создания отчета о состоянии пациента после тестирования данных.

Часть изображения, содержащая опухоль, обычно имеет большую интенсивность, чем другая часть изображения. В этом случае используются основные шаги алгоритма по обнаружению опухоли, которые реализованы в разработанном алгоритме и программном коде. В то же время, для области с оценочным содержанием интересующего объекта может быть проведена дополнительная обработка с учетом факторов, необходимых для анализа.

### 2.2.1. Улучшение контрастности изображений

Первоочередной задачей предварительной обработки является улучшение качества изображений изучаемой локальной области (опухоль головного мозга и молочной железы) на МРТ и создание формы, пригодной для дальнейшей обработки системой человеческого или машинного зрения. Кроме того, препроцессирование позволяет улучшить определенные параметры МРТ, такие как соотношение сигнал/шум, улучшение внешнего вида медицинского изображения, удаление несущественных шумов и нежелательных участков на фоне, сглаживание внутренней части области и сохранение ее краев [40].

Для улучшения соотношения сигнал/шум, а значит и чистоты исходных МРТ изображений, применяем адаптивное усиление контраста на основе модифицированной функции, описанной в [83]. Низкое качество изображения является препятствием для эффективного извлечения, анализа, распознавания и количественных измерений параметров. Медицинские изображения часто загрязнены аддитивными, импульсными или мультипликативными шумами из-за ряда неидеальных характеристик процесса получения изображений.

Для улучшения контрастности выделения интересующей области исследователи предложили использовать технологию «Техника Повышения Контрастности Баланса» (ТПКБ) [116]. Как правило, во время медицинской обработки изображений контрастность требуется для интересующей области.

В статьях [29, 137] описана методика Contrast Limited Adaptive Histogram Equalization (CLAHE) для улучшения характеристик и получения лучших характеристик медицинских изображений для адекватной диагностики.

Нерезкое маскирование – еще один интересный подход для улучшения изображения. Целью является улучшение кромок и деталей, но использование высокочастотного излучателя также делает этот метод чрезвычайно чувствительным к шумам. В своей работе [60] автор показал, что инвариантное контурное преобразование (STICT) улучшает качество МРТ-сканирования.

В предлагаемой методике используем алгоритм (ТПКБ). Контрастность изображения можно растягивать или сжимать без изменения формы гистограммы входного изображения ( $I_{Old}$ ). Решение основано на параболической функции, получаемой из входного изображения. Общая форма параболической функции определяется следующим образом:

$$I_{New} = a \cdot (I_{old} - b)^2 + c \quad (2.1)$$

Коэффициенты  $a$ ,  $b$  и  $c$  выведены из входа, минимального значения выходного изображения ( $I_{New}$ ), максимального значения выходного изображения и среднего значения выходного изображения:

$$b = \frac{h^2 \cdot (E - L) - s \cdot (H - L) + l^2 \cdot (H - E)}{2 \cdot [h \cdot (E - L) - e \cdot (H - L) + l \cdot (H - E)]}, \quad (2.2)$$

$$a = \frac{H - L}{(h - l)(h + l - 2b)}, \quad (2.3)$$

$$c = L - a(l - b)^2, \quad (2.4)$$

$$s = \frac{1}{N} \sum_{i=1}^N I_{Old}^2(i). \quad (2.5)$$

где  $l$  и  $h$  – минимальные и максимальные значения входного изображения, соответственно,  $e$  – среднее значение входного изображения,  $L$  и  $H$  – минимальное и максимальное значения выходного изображения, а  $s$  – средняя квадратная сумма входного изображения.

Как показано на рисунках 2.2 и 2.3, результаты использования разных реализаций ТПКБ, вместо использования разных порогов, поскольку МРТ сканирование содержит разный контраст и в этом случае сегментацию, а не точную томограмму.

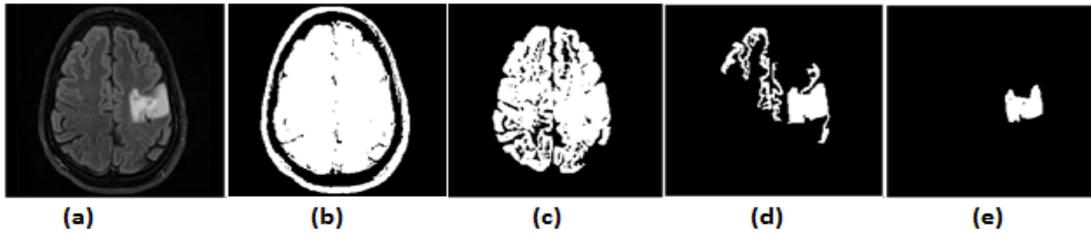


Рисунок 2.2 – Пример сегментации объекта (опухоли головного мозга) для различных средних значений ТПКБ: а) исходное изображение, б) ТПКБ 120, с) ТПКБ 100, d) ТПКБ 80, е) ТПКБ 60

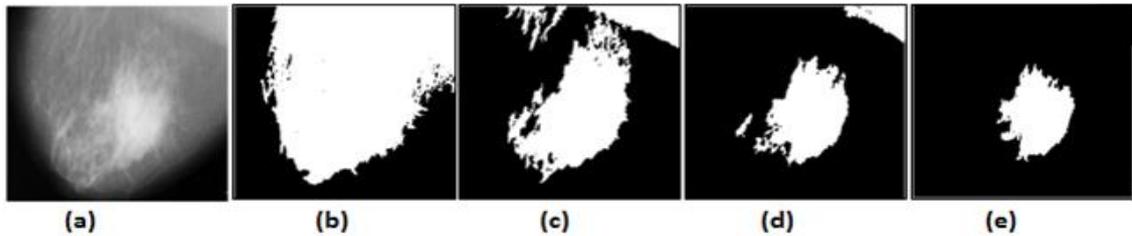


Рисунок 2.3 – Пример сегментации объекта (опухоли молочной железы) для различных средних значений ТПКБ: а) исходное изображение, б) ТПКБ 120, с) ТПКБ 100, d) ТПКБ 80, е) ТПКБ 60

### 2.2.2. Метод сегментации объектов

Сегментация изображения обычно используется для определения местоположения объектов и границ (линий, кривых и т.д.) на изображениях. Сегментация медицинских изображений для обнаружения локального объекта (опухолей головного мозга и молочной железы) с помощью магнитно-резонансных (МРТ) изображений или других методов медицинской визуализации является важным процессом для принятия правильного решения о терапии в короткое время [119, 125].

Наиболее важной частью медицинской обработки изображений является сегментация изображений. Сегментация изображения – это процедура выделения интересующей области (ROI) с помощью автоматического или полуавтоматического процесса. Многие методы сегментации изображения использовались в медицинских целях для сегментации тканей и органов тела. Некоторые из приложений включают в себя обнаружение границ на

ангиограммах коронарных артерий, хирургическое планирование, моделирование операций, обнаружение и сегментацию опухолей, исследование развития мозга и животных, функциональное картирование, автоматическую классификацию клеток крови, обнаружение массы в маммограммах, регистрацию изображений, сегментацию сердца и анализ изображений сердца и др. [42, 127].

В диссертации разработан метод пороговой итерации для сегментирования объектов (опухолей) и не инфицированных областей (головного мозга и молочной железы) на изображениях МРТ и КТ на основе улучшенного Оцу и нечеткой кластеризации С-средних, как показано на рисунке 2.4.

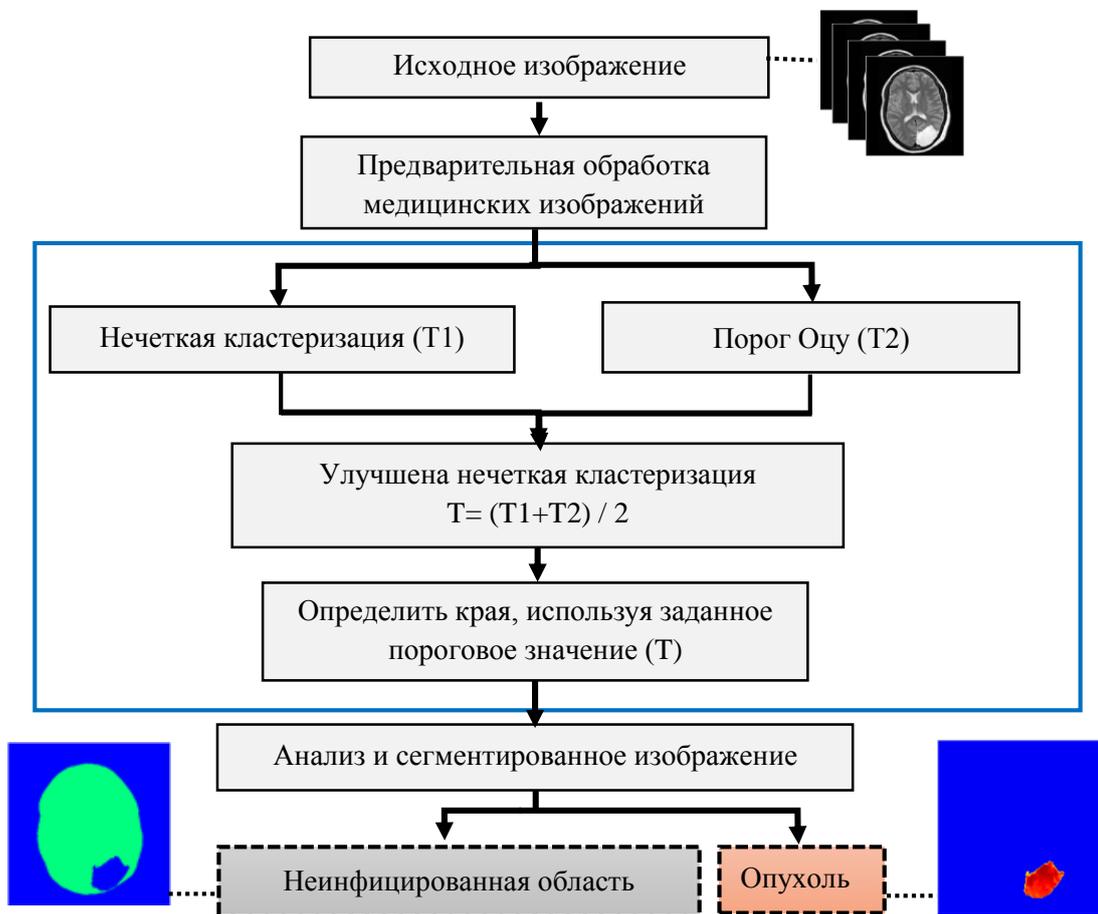


Рисунок 2.4 – Блок-схема разработанного метода пороговых нечетких С-средних

Пусть интенсивность изображения уровня серого выражается в  $L$  уровнях серого  $[1, 2, \dots, L]$ . Количество точек с уровнем серого  $p$  ( $i$ ) обозначается через  $x_i$ , а все количество точек может быть выражено как  $X = x_1 + x_2 + \dots + x_L$ ,

гистограмма этого изображения уровня серого рассматривается как распределение вероятности возникновения:

$$p(i) = \frac{x_i}{X}, x_i \geq 0, \sum_{i=1}^L x_i = 1. \quad (2.6)$$

Пиксели изображения делятся на две части  $C_0$  и  $C_1$ , передний план и задний фон с пороговым значением  $t$ , где  $C_0$  повторно представляет пиксели в пределах уровней  $[1, 2, \dots, t]$ , а  $C_1$  – обозначает пиксели в пределах уровней  $[t + 1, \dots, L]$ . Вероятности возникновения этого класса и среднего могут быть выражены, соответственно:

$$w_0 = w(t) = \sum_{i=1}^t p(i), \quad (2.7)$$

$$w_1 = 1 - w(t) = \sum_{i=t+1}^L p(i), \quad (2.8)$$

$$\mu_0 = \sum_{i=1}^t \frac{i \cdot p(i)}{w_0} = \frac{1}{w(t)}, \quad (2.9)$$

$$\mu_1 = \sum_{i=t+1}^L \frac{i \cdot p(i)}{w_1} = \frac{1}{1-w(t)} \sum_{i=t+1}^L i \cdot p(i). \quad (2.10)$$

Общее среднее можно записать в виде:

$$\mu_T = \sum_{i=1}^L i \cdot p(i). \quad (2.11)$$

и далее можем найти:

$$\mu_T = w_0 \mu_0 + w_1 \mu_1, \quad (2.12)$$

где  $w_0$  и  $w_1$  – обозначают вероятности переднего и фоновых участков. Кроме того,  $\mu_0$ ,  $\mu_1$  и  $\mu_T$  относятся к среднему уровню серых уровней переднего плана серого изображения, фоновому изображению серого изображения и всего изображения уровня серого.

Вариант между классами  $\sigma_B^2$  из двух частей  $C_0$  и  $C_1$  может быть перезаписан как:

$$\sigma_B^2 = w_0 (\mu_0 - \mu_T)^2 + w_1 (\mu_1 - \mu_T)^2, \quad (2.13)$$

а порог качества  $t^*$  выбирается по максимизации  $\sigma_B^2$ :

$$t^* = \arg \max \sigma_B^2, \quad 1 \leq t \leq L. \quad (2.14)$$

Когда распределение для класса  $C_k$  ( $k = 0$  или  $1$ ) находится между регионами с различными характеристиками, известно, что медианное значение является надежным оценочным значением по сравнению со средним уровнем серого.

Тогда находим, что медианное значение замещения среднего может получить как  $t^*$ , что достаточно обоснованно с учетом наличия распределения  $C_K$  по сравнению с этими порогами, выбранными алгоритмом Оцу.

Следовательно, можем заменить общее среднее значение  $\mu_T$  суммарным медианным уровнем  $m_T$  всех точек на всем изображении уровня серого. аналогично среднему значению  $\mu_T$  всего изображения. Средние значения  $\mu_0$  и  $\mu_1$  также могут быть заменены срединными уровнями серого  $m_0$  и  $m_1$  передней части  $C_0$  и задней части  $C_1$ , соответственно. Вариант между классами  $\sigma_B^2$  из двух частей  $C_0$  и  $C_1$  может быть перезаписан как:

$$\sigma_B^2 = w_0 (m_0 - m_T)^2 + w_1 (m_1 - m_T)^2, \quad (2.15)$$

а порог качества  $t^*$  выбирается по максимизации  $\sigma_B^2$  :

$$t^* = \arg \max \sigma_B^2, \quad 1 \leq t \leq L. \quad (2.16)$$

### 2.2.3. Детектирование и контурирование объектов

Контурная карта может быть сгенерирована с использованием различных алгоритмов, таких как Робертс, Преуитт, Собел, и более сложных, например, LoG, вейвлет, шиарлет и Кэнни. Усовершенствованный метод низкочастотного обнаружения края на основе улучшенного оператора Кэнни является наиболее эффективным детектором из нескольких операторов обнаружения края в области обработки изображения, как описано выше в 1.5.1.

Этот метод способен воспринимать широкий диапазон краев изображения, поскольку он точно соответствует общим критериям для обнаружения краев, а процесс реализации довольно прост [57]. После разделения изображения на серию однородных классов с использованием разработанного метода сегментации используется улучшенный оператор Кэнни. Он основан на значении градиента пикселя и используется для определения мелкого края, в то время как изображение включает в себя однородные области. Этапы этого метода могут быть описаны следующим образом.

На первом этапе для сглаживания исходных изображений используется гауссовый фильтр. Кроме того, для каждого пикселя изображения определяются величина и направление градиента. Следующим шагом является выбор граничных пикселей (крайних пикселей). Пиксель считается граничным пикселем, если значение градиента этого пикселя больше, чем у двух соседей в направлении градиента.

Пример поэтапного формирования карты контуров в соответствии с предложенной методикой показан на рисунке 2.5 для опухоли головного мозга (а) исходное изображение; б) и с) изображения предварительной обработки; д) результат после кластеризации FCM; е) результат после порогового значения Оцу; ф) результат разработанного метода; г) комбинированное изображение с цветовой картой; h) карта конечного края для областей головного мозга и опухоли.

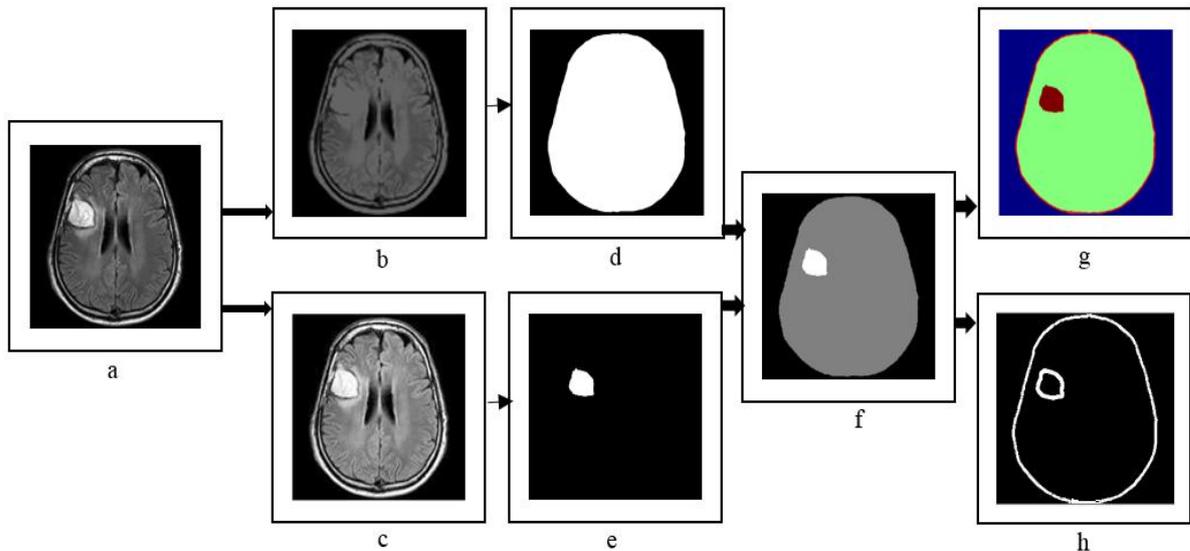


Рисунок 2.5 – Пример комбинированной сегментации и контурной детекции объекта (опухоли головного мозга)

На рисунке 2.6 для опухоли молочной железы: а) исходное изображение; б) результат после кластеризации FCM; с) результат после порогового значения Оцу; д) результат разработанного метода; е) карта конечного края для областей молочной железы и опухоли; ф) комбинированное изображение с цветовой картой.

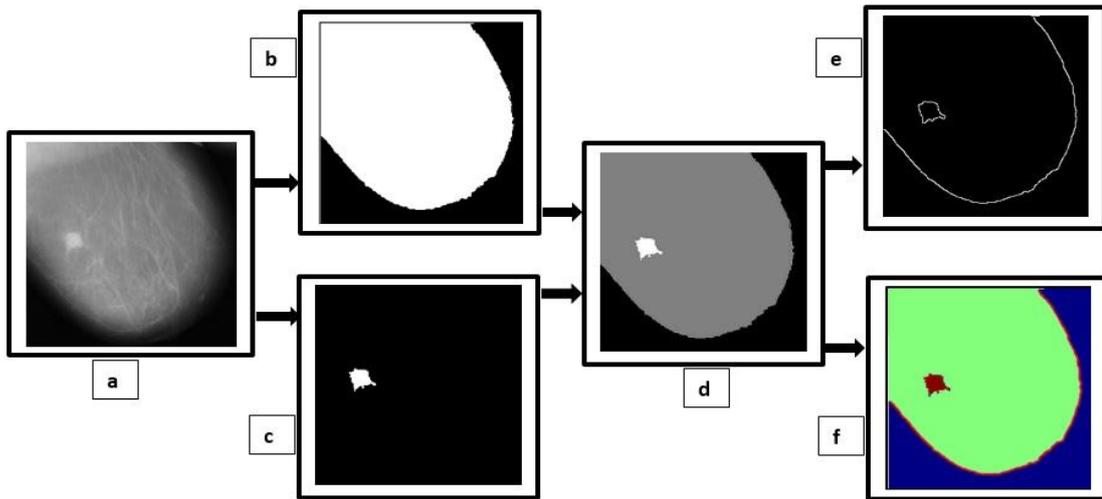


Рисунок 2.6 – Пример комбинированной сегментации и контурной детекции объекта (опухоли молочной железы)

#### 2.2.4. Извлечение признаков

Точность классификации объектов зависит от качества извлеченных признаков. Мы предложили алгоритм классификации для выделения особенностей сегментированного объекта с использованием дискретного вейвлет-преобразования (DWT) и матрицы взаимодействия уровня серого (GLCM). Этот этап является наиболее важным в нашей вычислительной методике, так как точность процесса классификации зависит от качества извлекаемых признаков. В рамках этой вычислительной процедуры принимаются входные изображения (МРТ) и возвращаются дискретное вейвлет-преобразование (DWT) для МРТ. Затем коэффициенты DWT анализируются путем вычисления 13 статистических значений, которые представляют собой извлеченные особенности.

Определения и формулы для этих статистических значений приведены в разделе 1.4.1. В своей работе мы использовали различные значения смещения при вычислении матрицы DWT. Однако наилучшая точность классификации получена при значениях смещения  $[2\ 0]$  и  $[2\ 0, 0\ 2]$ , которые будем называть смещением 1 и смещением 2, соответственно. Этап извлечения элемента контура одинаков как для фазы обучения, так и для фазы тестирования.

Матрица кооперации уровня серого (GLCM) является надежным способом статистического анализа изображений. Используется для оценки характеристик изображений по статистике второго порядка. Матрица метода GLCM определяется как двумерная матрица совместной вероятности между парами пикселей над изображением ( $I$ ) как распределение совместно встречающихся значений при заданном смещении ( $dx, dy$ ) для изображения с размером  $N \times M$ :

$$C_{dx,dy}(i, j) = \sum_{p=1}^N \sum_{q=1}^M \begin{cases} 1, & \text{if } I(p, q) = i \text{ and } I(p + dx, q + dy) = j \\ 0, & \text{otherwise} \end{cases} \quad (2.17)$$

Выбраны характеристики [17, 101]: Энергия (F1), Контраст (F2), Корреляция (F3), Автокорреляция (F4), Энтропия (F5), Гомогенность (F6), Несоответствие (F7), Кластерный оттенок (F8), Протуберанец кластера (F9), Максимальная Вероятность (F10), Сумма квадрата (F11), Момент обратной разности (F12), Суммарное среднее (F13), Суммарное отклонение (F14), Суммарная энтропия (F15), Различное отклонение (F16), Различная энтропия (F17) и Информационное измерение корреляции (F18). Для получения лучших результатов классификации сгенерированы матрицы GLCM для различных смещений (от 2 до 4 пикселей) и углов ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  и  $135^\circ$ ).

Выделенные признаки (на основе области объекта – опухоли) и выбранные из сегментированных изображений, затем классифицированы с использованием методов нейронной сети для диагностики наличия у пациента (доброкачественной опухоли) или (злокачественной опухоли). Реализация комбинации методов повышает точность результатов и оценок.

### 2.2.5. Классификация локальных объектов (опухолей)

Рассмотрим процесс бинарной классификации, при котором классификатор определяет, является ли обнаруженная опухоль доброкачественной или стадией злокачественной.

Для выполнения своей роли классификатор использует извлеченные элементы в дополнение к ранее усвоенным знаниям. Вероятностная нейронная

сеть (PNN) используется в качестве классификатора объектов (опухолей головного мозга) на основе экстрагированных признаков с использованием преобразования GLCM и алгоритма опорного вектора (SVM) – в качестве классификатора опухолей молочной железы на основе экстрагированных признаков с использованием DWT.

#### 2.2.5.1. Классификация локального объекта с использованием PNN

Вероятностные нейронные сети могут быть использованы для решения задач классификации. При отображении входа первый слой вычисляет расстояние от входного вектора до учебных векторов и создает вектор, элементы которого показывают, насколько близко входной вектор находится к входу обучения.

Второй уровень суммирует эти вклады для каждого класса, чтобы получить в качестве чистого выпуска вектор вероятностей. Наконец, конкурирующая передаточная функция на выходе второго уровня выбирает максимум этих вероятностей и определяет 1 для этого класса и 0 для других классов [6, 16].

Вероятностная нейронная сеть Парцена (PPNN) – это простой тип нейросетей, используемый для классификации векторов данных. Эти классификаторы действительно быстры, просты в изучении и основаны на байесовской теории, где апостериорная плотность вероятности оценивается по данным, полученным методом парценового окна [129]. Хорошие результаты классификации могут быть получены для определенного класса распределения данных.

Байесовские классификаторы используют байесовское уравнение для оценки плотности вероятности  $P(w_i | x)$ :

$$P\left(w_i \frac{1}{x}\right) = \frac{P(x/w_i) P(w_i)}{\sum_i P(x/w_i) P(w_i)} . \quad (2.18)$$

Очевидно, что этот метод требует, чтобы были известны вероятности  $P(x|w_i)$  и  $P(w_i)$ . Методика заключается в параметризации этих pdf, другая – в их оценке по данным. Техника «замороженного окна» оценивает вероятность определения

окна (при заданном размере окна) и функции на этом окне (т.е. гиперсферы с усеченной гауссовской функцией внутри). Очевидно, что для поддержания шкалы в оценочном pdf оконная функция должна иметь интеграл (гиперобъем под функцией), равный 1.

Следовательно, алгоритм PPNN является простым инструментом, который представляет собой состав оценки функция плотности вероятности (PDF) с окном Парзена и байесовской классификацией. В этом кратком объяснении конкретные производные не приводятся, но можно найти их в работе [104].

Соответственно, Parzen PNN – это четырехслойная нейронная сеть (NN), в которой входные данные полностью связаны с первым нейронным слоем, а первый слой слабо связан со вторым (и выходным) слоем (рисунок 2.7). Выходной слой состоит из  $c$  нейронов, где  $c$  – число классов классификатора.

Веса на первом уровне обучаются следующим образом: Каждое отсчетное значение образца нормируется таким образом, что его длина становится унитарной; каждое отсчетное значение образца становится нейроном с нормированными значениями в виде весов  $w$ .

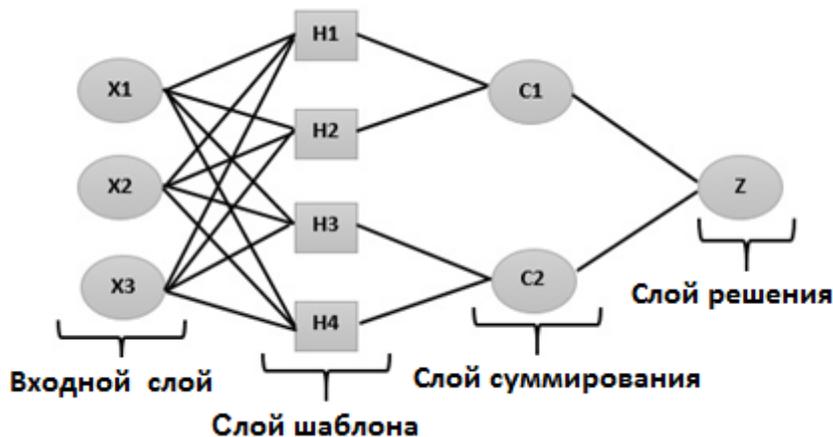


Рисунок 2.7 – Архитектура четырехслойной PNN для  $n$  учебных кейсов из двух классов

Входные данные  $x$  настолько многоточечны, что веса, получающие сигнал активации сети (сети), определяются в виде:

$$net = w^{x^T} \quad (2.19)$$

Затем вычисляется экспоненциальная нелинейность для получения сигналов синаптической активации (действовать) в соответствии с уравнением:

$$act = \exp \left[ \text{sigm} \left( \frac{net+1}{2} \right) \right] \quad (2.20)$$

В процессе обучения каждый нейрон первого слоя подключается к нейрону выходного слоя, относящемуся к своему классу с весом 1. В процессе классификации выходной нейрон каждого класса суммирует сигналы активации от всех нейронов первого слоя, т.е. самое большое выходное значение выбирает класс входных данных.

#### 2.2.5.2. Классификация локального объекта с использованием SVM

Целью этого этапа является представление системы автоматизированной диагностики (CAD) для автоматического обнаружения опухолей головного мозга на изображениях магнитного резонанса (МРТ) головного мозга. Предложенный алгоритм позволяет классифицировать два разных типа опухолей головного мозга (доброкачественные и злокачественные). Система состоит из трех основных этапов, а именно: сегментации изображения, выделения и выбора признаков и, наконец, этапа классификации. Мы использовали разработанный метод сегментации в качестве методов для сегментации изображения и дискретного вейвлет-преобразования (DWT) в качестве метода для выделения признаков.

Алгоритм SVM определяет гиперплоскость, которая разделена на два учебных класса, как это определено в уравнении:

$$f(y) = Z^T \phi(y) + b, \quad (2.21)$$

где  $Z$  и  $T$  являются гиперплоскостными параметрами, а  $\phi(y)$  – функцией, используемой для отображения вектора  $y$  в более высокоплоскостное пространство.

Уравнение (2.22) обеспечивает гауссовскую функцию ядра нелинейной SVM [46, 47], используемой для оптимального решения классификации и обобщения, а ее расширенная функция классификации показана в виде (2.23):

$$k(y_i, y_j) = \exp[-y \|y_i - y_j\|^2], \quad (2.22)$$

$$k(y_i, y_j) = \sum_{i=1}^N \sum_{x_i \in M_j} (\exp[-y \|y_i - y_j\|^2]), \quad (2.23)$$

где  $y_i$  и  $y_j$  – объекты  $i$  и  $j$ , соответственно, а  $y$  – параметр контура, используемый для определения гладкости пограничной области. Выбор функций с возможностью изменения класса ядра делает алгоритм SVM выбором по умолчанию для классификации опухоли головного мозга (доброкачественной или злокачественной).

### 2.3. Вычислительные эксперименты

В этом экспериментальном исследовании мы использовали два набора данных для анализа объектов (опухолей мозга). Первый набор данных – это набор данных по цифровой визуализации (DICOM) [55]. Для целей анализа исследователи рассмотрели 150 изображений из набора данных DICOM, все из которых являются с опухолями головного мозга.

Вторым набором данных является набор данных BrainWeb [20], который состоит из полных трехмерных данных МРТ мозга, смоделированных с помощью трех последовательностей модальностей, а именно: T1-взвешенной МРТ, T2-взвешенной МРТ. В этом наборе данных 15 из 48 включенных изображений содержат опухоли головного мозга. Дополнительный набор данных по опухолям головного мозга, собранных у специалистов-рентгенологов, включал образцы изображений 10 пациентов с 6 снимками для каждого пациента. Для МРТ молочной железы в экспериментальном исследовании отобрано 75 изображений из снимков МРТ и цифровой базы данных для скрининговой маммографии (DDSM) [59].

Эксперименты выполнялись на разнообразных изображениях размером 256 x 256. Здесь приведены результаты некоторых случаев сегментации и обнаружения опухолей головного мозга, показанные на рисунке 2.8, упорядоченные слева направо.

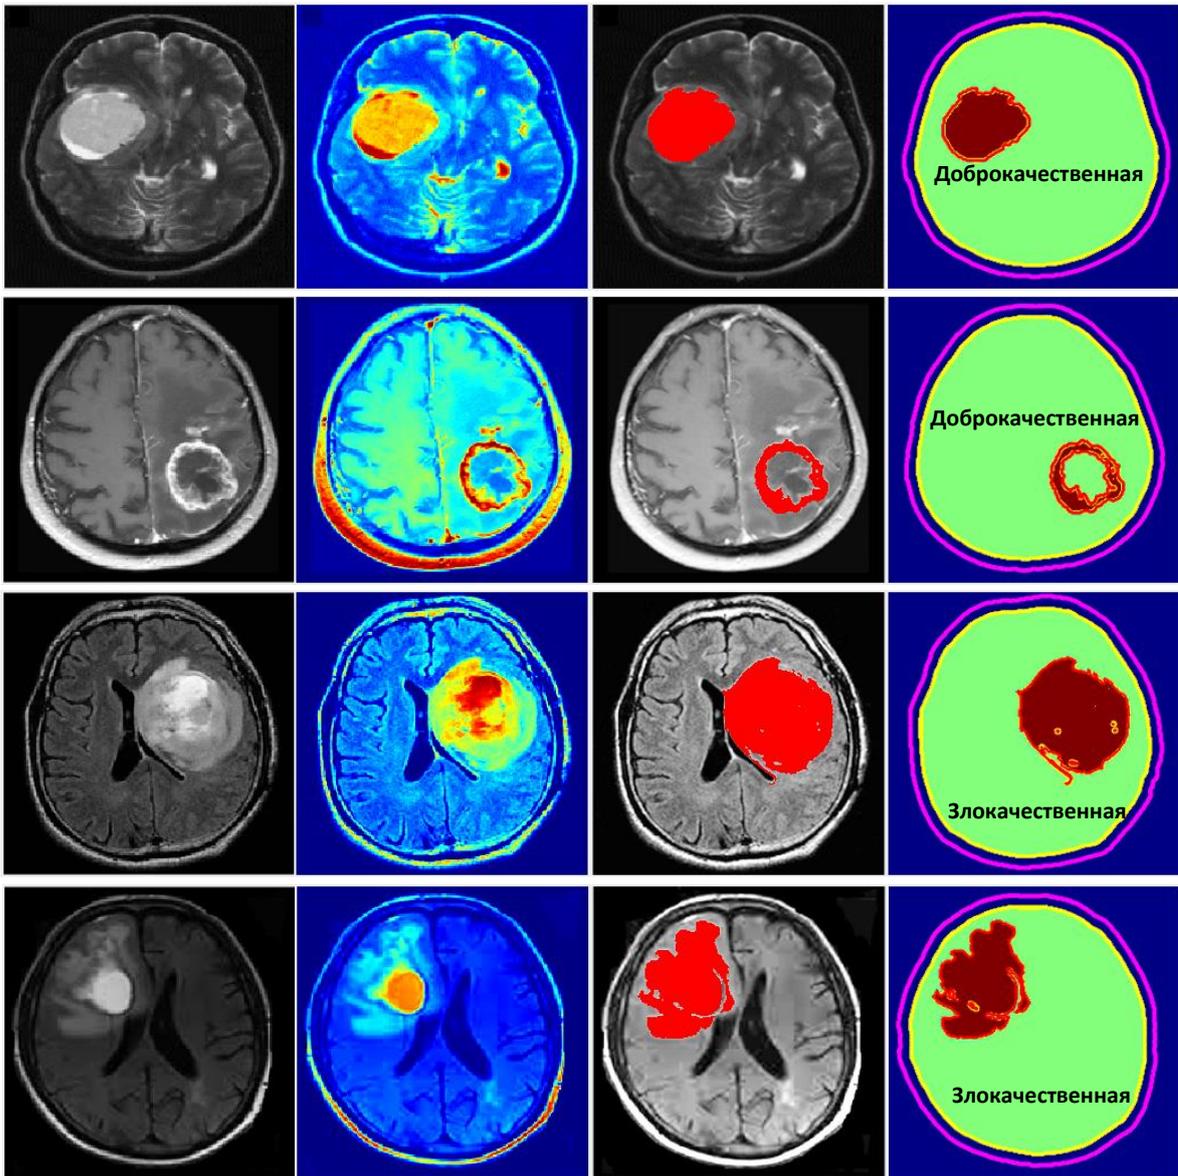


Рисунок 2.8 – Некоторые результаты применения метода для определения положения объекта (опухоли мозга)

Первая колонка представляет собой оригинальные изображения головного мозга, вторая колонка представляет результаты после этапа предварительной обработки и показана на цветной карте, третья колонка изображения – сегментации по областям и контуры последней колонки – пораженные опухолью области, а также нормальные области головного мозга (без патологии).

Примеры МРТ молочной железы, полученные в ходе проведения вычислительного эксперимента по сегментации и выявлению опухолей молочной железы, показаны на рисунке 2.9. Также видно, что яркость и контрастность изображения варьируется от изображения к изображению, где в

верхнем ряду представлены исходные изображения (цифровая база данных для скрининговой маммографии (DDSM)), упорядоченные слева направо.

Первая колонка представляет исходные изображения, вторая колонка представляет результаты изображения после этапа предварительной обработки и показана в цвете с использованием цветовой карты, что объяснялось в разделе выше. В данном варианте расчета изображения сегментации по областям – в третьей колонке, а в последней колонке – результат после маскировки и обработки (конечные контурные изображения). Дифференцируя нормальные клетки и опухолевые клетки, это также помогает рассчитать площадь опухоли, приведены вычисления величины площади в единицах пикселя.

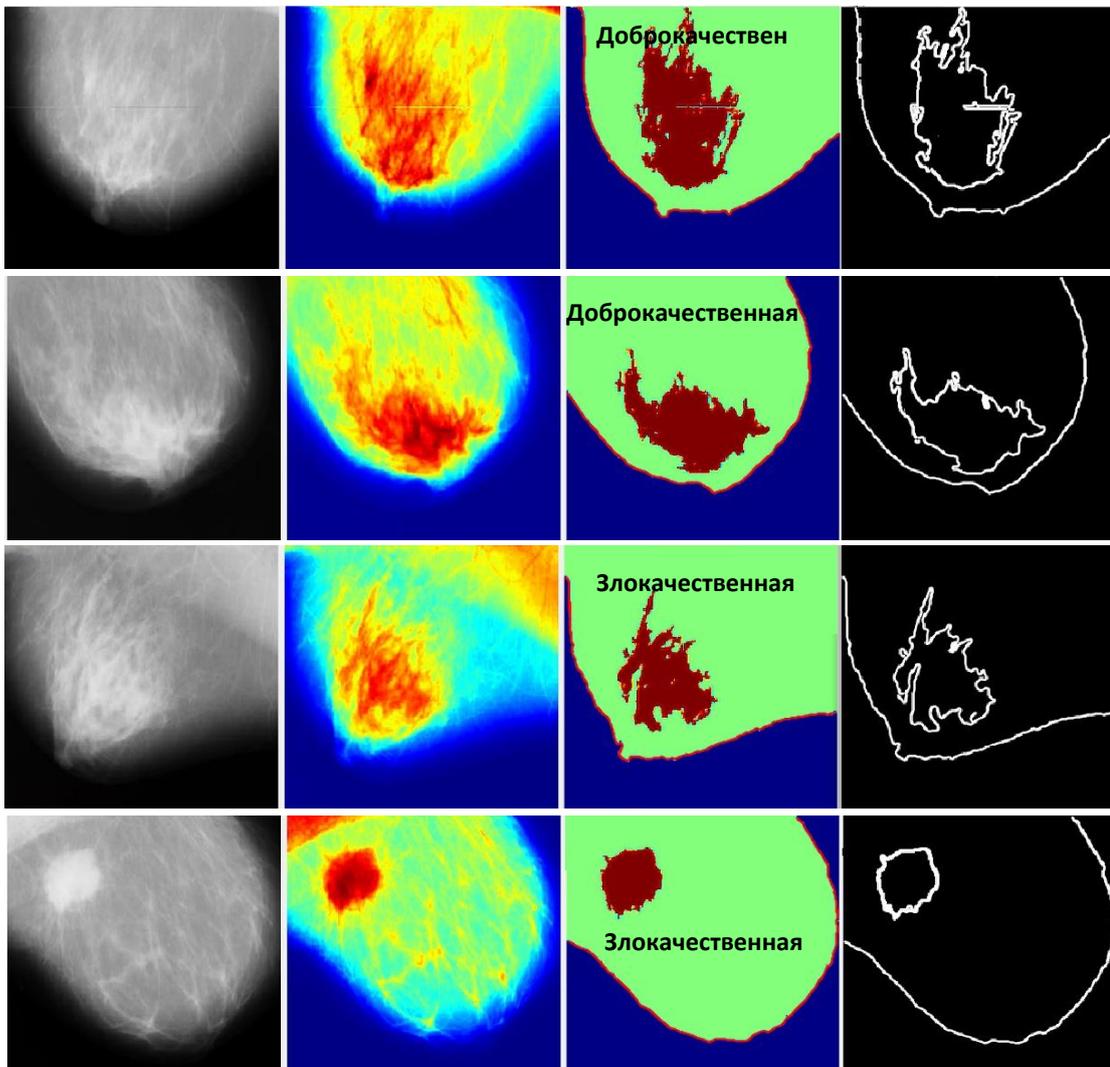


Рисунок 2.9 – Некоторые результаты применения метода для определения положения объекта (опухоли молочной железы)

Показано сравнение разработанного алгоритма с методами [1, 21, 147, 152, 155] для оценки опухоли головного мозга и с методами [39, 43, 94] для выявления и сегментации опухоли молочной железы. Благодаря визуальному анализу становится ясно, что наш алгоритм способен сегментировать опухоли и нормальные участки лучше, чем другие методы.

Там, где методы в [1, 21, 147, 152, 155] и [39, 43, 94] включают некоторую неопухолевую область на пятничном сегментированном изображении, неоднозначном для диагностики (без границ опухолей и нормальных областей головного мозга и молочной железы), наш метод обнаруживает опухолевую область (а также нормальную область головного мозга и молочной железы на исходном входном изображении) успешно с цветовым результатом, как показано на рисунках 2.8 и 2.9.

Для оценки достоверности и корректности опухоли и карты нормальной области головного мозга и края молочной железы, полученной предложенным методом, использованы следующие параметры: индекс структурированного сходства (SSIM), средняя квадратная ошибка (MSE), отношение пикового сигнала к шуму (PSNR) в дБ, процент обнаруженных пикселей ( $P_{CD}$ ), процент не обнаруженных пикселей ( $P_{ND}$ ), процент ложных срабатываний ( $PFA$ ), показатель заслуг ( $FOM$ ), чувствительность и точность.

Эти параметры в основном зависят от значений  $TP$ ,  $TN$ ,  $FP$ ,  $FN$ :

- истинный положительный ( $TP$ ), количество пикселей, правильно идентифицированных как граница опухоли;
- отрицательный ( $TN$ ), количество пикселей, правильно обнаруженных в качестве фона;
- ложноположительный ( $FP$ ), количество пикселей, ложно идентифицированных как граница опухоли;
- ложно-отрицательный ( $FN$ ), количество пикселей, ложно обнаруженных в качестве фона;

Индекс структурного сходства (SSIM) является метрикой восприятия, означающей, что ухудшение качества изображения может быть вызвано сжатием

данных или потерями при их передаче или любыми другими способами обработки изображения. Он определяется как:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}. \quad (2.24)$$

Более высокое значение SSIM указывает на лучшее сохранение яркости, контрастности и структурного содержания.

Среднеквадратичная ошибка (MSE) является мерой точности сигнала или изображения. Цель измерения точности сигнала или изображения – найти сходство между двумя изображениями путем предоставления количественной оценки. При расчете MSE предполагается, что одно из изображений является оригиналом, в то время как другое искажено или обработано тем или иным способом и определено как:

$$MSE = \frac{1}{N} \sum_{i=1}^N E_i^2 = \frac{\|E\|^2}{N}. \quad (2.25)$$

Пиковое отношение сигнал / шум (PSNR) является мерой, используемой для оценки качества восстановления обработанного снимка, и определяется как:

$$PSNR = 10 \log_{10} \left( \frac{(2^n - 1)^2}{MSE} \right) = 20 \log_{10} (2^n - 1) - 20 \log_{10} \left( \frac{\|E\|}{\sqrt{N}} \right). \quad (2.26)$$

Меньшее значение MSE и большее значение PSNR указывают на лучшее соотношение сигнал/шум.

Показатель Figure of Merit (FOM) является еще одной полезной мерой для оценки работы краевых детекторов. Эта мера использует расстояние между всеми парами точек, соответствующий количественно с точностью, разность между контурами. Показатель FOM, который оценивает сходство между двумя контурами, определяется как:

$$FOM = \frac{1}{\max(RE_{Cnt}, AE_{Cnt})} \cdot \sum_{i=1}^{AE_{Cnt}} \frac{1}{1 + \alpha \cdot d_i^2}, \quad (2.27)$$

где  $RE_{Cnt}$  и  $AE_{Cnt}$  – число идеалов (эталон) и действительная точка на краю;

$d_i$  – расстояние между пикселем на краю и ближайшим пикселем на краю эталона;  $\alpha$  – эмпирическая калибровочная константа (использовалась  $\alpha = 1/9$ , оптимальное значение).

Диапазон измерений лежит в диапазоне от 0 до 1, и максимальное значение является оптимальным. Чувствительность может быть описана уравнением:

$$\text{Чувствительность} = \frac{TP}{TP + FN} \cdot \quad (2.28)$$

Точность – это доля истинных результатов. Точность дает процент от того, сколько объектов и фоновых пикселей было точно обнаружено. Диапазон измерений лежит в диапазоне от 0 до 1. Если значение точности равно 1, то выходной сигнал совпадает с входным. Точность определяется как:

$$\text{Точность} = \frac{TP + TN}{TP + TN + FP + FN} \cdot \quad (2.29)$$

Из результатов наблюдения можно четко выразить, что обнаружение опухоли и нормальной области головного мозга и МРТ молочной железы происходит быстро и точно по сравнению с ручным выявлением, выполненным клиническими специалистами.

Наиболее часто используемые показатели в области техники сегментации и классификации медицинских изображений с помощью нейронных сетей представляют собой показатели Intersection Over Union (IoU) Metric, описанную в уравнении (2.30), и Dice Similarity Coefficient (DCS) (в уравнении (2.31)). Показатели IoU или Jaccard index состоят из количественного определения процента перекрытия между маской истинности и прогнозируемой выходной маской. Этот показатель тесно связан с коэффициентом подобия игральные кости, который часто используется в качестве функции точности во время обучения:

$$IoU = \frac{TP}{TP + FP + FN} \cdot \quad (2.30)$$

$$DSC = \frac{2TP}{2TP + FP + FN} \cdot \quad (2.31)$$

Оцененные факторы производительности также показывают, что это дает лучшие результаты за счет улучшения параметров SSIM, PSNR и MSE. Предложенная методика приводит к точному и быстрому обнаружению объекта (опухоли в головном мозге и молочной железы) наряду с определением точного местоположения опухоли и нормальных областей в изображениях МРТ. Анализ эффективности изображений, обнаруженных по краям с расчетом площади опухолей и площади области без патологии (головного мозга и молочной железы), представлены в таблицах 2.1 и 2.2.

Таблица 2.1 – Параметры анализа эффективности выявленных тканей и площади удаленных опухолей и области без патологии.

Снимки	Выделенная область опухоли (пиксель)	Выделенная область нормального мозга (пиксель)	Размер опухоли %	PSNR	MSE	SSIM	DSC	Время выполнения в секундах
С 1	4566	40064	11%	67.011	2.121	0.9610	0.9705	23.0797
С 2	3693	45496	8%	65.82	1.116	0.9546	0.9579	22.1202
С 3	4347	42391	10%	66.12	1.068	0.9700	0.9650	24.0785
С 4	5706	44235	13%	68.86	2.77	0.9531	0.9722	21.8952
С 5	2271	46935	5%	67.79	1.84	0.9746	0.9649	22.2563
С 6	6025	40844	15%	66.82	1.79	0.9623	0.9795	20.7796

Таблица 2.2 – Параметры анализа эффективности выявленных тканей и площади удаленных опухолей и нормальной молочной железы.

Снимки	Выделенная область опухоли (пиксель)	Выделенная область нормального мозга (пиксель)	Размер опухоли %	PSNR	MSE	SSIM	DSC	Время выполнения в секундах
С 1	8940	41272	22%	68.990	1.920	0.9565	0.9562	24.1257
С 2	7025	39541	18%	64.004	1.35	0.9675	0.9639	23.5863
С 3	2029	43394	5%	65.066	1.215	0.9700	0.9698	25.5863
С 4	4311	45380	9%	64.03	2.172	0.9663	0.9750	23.02236
С 5	1956	46811	4%	66.256	1.245	0.9726	0.9658	26.8860
С 6	15561	44600	35%	67.504	1.757	0.9623	0.9785	24.0563

Чтобы показать, что предлагаемая методика обладает хорошей способностью обнаружения краев и устойчива к среднему уровню шума, проведены следующие исследования. Первое исследование предполагает

сравнение предложенного метода с классическими подходами к обнаружению кромок, основанными на простых градиентных операторах, таких как Roberts, Prewitt, Sobel и сложных методах LoG и Canny.

Для сравнения выбраны изображения с наименее выраженным шумовым воздействием. Все показатели оценки в ходе исследования рассчитаны с помощью эталонных изображений, созданных медицинским экспертом. Демонстрируется сравнение нескольких методов формирования контурного представления (краевой карты) опухолей головного мозга и молочной железы для первых моделей изображений, показанных на рисунках 2.8 и 2.9, а также приведенных в таблицах 2.3 и 2.4.

Таблица 2.3 – Сравнение карт краев, генерируемых опухолью и нормальными клетками головного мозга, различными методами обнаружения краев для модельных изображений.

Модель изображения	Методы	FOM	Чувствительность	Точность
Изображение а	Разработанный метод	0,9025	0,8789	0,9725
	Classic Canny	0,5803	0,2169	0,8519
	Prewitt	0,3298	0,2347	0,7369
	Roberts	0,4236	0,1846	0,8409
	Sobel	0,3026	0,2364	0,6432
	LoG	0,2254	0,1116	0,7018

Таблица 2.4 – Сравнение карт краев, генерируемых опухолью и нормальными клетками молочной железы, различными методами определения краев для модельных изображений

Модель изображения	Методы	FOM	Чувствительность	Точность
Изображение а	Разработанный метод	0,9158	0,9489	0,9731
	Classic Canny	0,5532	0,1557	0,8476
	Prewitt	0,4523	0,0727	0,7579
	Roberts	0,4236	0,0366	0,7586
	Sobel	0,358	0,0749	0,5579
	LoG	0,2564	0,0673	0,6013

Предложенный метод позволяет получить карту краев интересующего объекта (область опухоли и нормальные области) с большей точностью в среднем на 3-7%. Кроме того, предложенный метод демонстрирует меньший процент пикселей, ошибочно обнаруженных в виде краев опухолей головного мозга и молочной железы. Изменение составляет менее одного процента для уровня шума ниже 10%. Тем не менее, индекс чувствительности показывает более заметное снижение, находясь в допустимом диапазоне.

В таблице 2.5 представлен обзор современных методов (с 2016 года) с использованием сверточной нейронной сети и других алгоритмов сегментации для различных задач сегментации медицинских изображений.

Таблица 2.5 – Современные методы, использующие различные алгоритмы в сегментации медицинских изображений.

Год	Методы	Приложение сегментации	Модальность	Точность (%)	Метрический
2018 [14]	Genetic Algorithm	Опухоли г. мозга	MR images	92.03	DSC
2017 [38]	2 conductive U-Nets	Опухоли м. железы	MRI-T1	94.30	DSC
2019 [43]	U-Net	Опухоли м. железы	MRI-T1	76.14	IoU
2019 [70]	Fuzzy C-mean	Опухоли г. мозга	CT images	91.18	DSC
2016 [100]	V-Net (Volumetric U-Net)	Предстательная железа	MRI (T1,T2)	82.39	DSC
2019 [147]	CNN Approach	Опухоли м. железы	MR images	91.05	DSC
2017 [148]	CNN Approach	Опухоли г. мозга	MR images	90.50	DSC
2018 [161]	Bayesian CNN	Экстракция мозга приматов	MRI-T1	95.00	DCS
<b>Разработанный метод</b>	FcM + Otsu Threshold	Опухоли г. мозга и м. железы	MR and CT images	96.85	DSC
				94.74	IoU

Из таблицы 2.5 видно, что разработанный метод отличается высокой точностью – 2-3% ошибки при сегментации медицинских изображений.

Для проверки точности классификаторов PNN и SVM проведено обучение по совместному набору МРТ-изображений из набора данных цифровой визуализации в медицине (DICOM).

Результаты и описания приведены в таблице 2.6 для классификации опухолей головного мозга и в таблице 2.7 для классификации опухолей молочной железы.

Таблица 2.6 – SVM классификатор точности опухоли головного мозга на МРТ изображениях.

Изображений	Без выделения признаков			С извлечением признаков		
	Количество изображений	Классифицировано %		Количество изображений	Классифицировано %	
		Правильно	Неправильно		Правильно	Неправильно
Изображения с опухолью (доброкачественные)	42	92.58	7.32	42	99.85	0.15
Изображения с опухолью (злокачественные)	36	95.65	6.35	36	98.96	1.04
Общее количество	78	95.11	13.67	78	99.02	1.17

Экспериментальные исследования показали, что средняя точность классификации составляет 99% при извлечении признаков и 95% без извлечения признаков, как можно отметить из таблицы 2.5.

Ошибки классификации доброкачественной и злокачественной опухоли головного мозга в снимках МРТ составляют около 1-2% с извлечением признаков и 3-4% без извлечения признаков.

Таблица 2.7 – Точность PNN классификатора опухоли молочной железы на КТ изображениях.

Изображений	Без выделения признаков			С извлечением признаков		
	Количество изображений	Классифицировано %		Количество изображений	Классифицировано %	
		Правильно	Неправильно		Правильно	Неправильно
Изображения с опухолью (доброкачественные)	20	94.88	3.12	20	98.96	1.04
Изображения с опухолью (злокачественные)	20	93.91	4.09	20	98.97	1.03
Общее количество	40	94.79	7.21	40	98.96	2.07

Экспериментальные исследования показали, что средняя точность классификации составляет 98% при извлечении признаков и 95% без извлечения признаков, как можно отметить из таблицы 2.6. Ошибки классификации доброкачественной и злокачественной опухоли головного мозга на снимках МРТ составляют около 1-2% с извлеченным признаком и 3-5 % без извлечения признаков.

#### 2.4. Выводы по второй главе

Получены следующие результаты.

1. Метод ВСЕТ предложен для повышения контрастности и выделения интересующей области на медицинских изображениях. Решение с помощью этого метода основано на параболической функции, полученной из входного изображения, как показано в уравнении 2.1.
2. Улучшен пороговый метод Оцу путем замены общего среднего значения  $\mu_T$  суммарным медианным уровнем  $m_T$  всех точек на всем изображении уровня серого, аналогично среднему значению  $\mu_T$  всего изображения; средние значения  $\mu_0$  и  $\mu_1$  также могут быть заменены срединными уровнями серого  $m_0$  и  $m_1$  передней части  $C_0$  и задней части  $C_1$ ,

соответственно.

3. Разработан новый метод сегментации по группам объектов, который характеризуется созданием нового порога для сегментации объектов с использованием комбинации порогового значения улучшенного алгоритма Оцу и нечеткой кластеризации, что позволяет значительно увеличить скорость и улучшить точность сегментации и классификации объектов на 2-3% по сравнению с современными методами медицинской сегментации (2016-2019 гг.). Результат показан в таблице 2.5.
4. В разработанном методе сегментации по отдельным объектам описан скалярный параметр для выбора объектов – пороговое расстояние между гистограммами распределения интенсивности. Предложен подход для разделения на отдельные объекты путем объединения суперпикселей.
5. Извлечены информационные функции из сегментированного объекта (опухоли) на изображениях МРТ и КТ; 18 функций извлечены с использованием GLCM, что позволило повысить точность классификации объектов (опухоль молочной железы) на 4-5%, и 13 функций извлечены с использованием DWT, что позволило повысить точность классификации объекта (опухоль головного мозга) на 3-4%, результаты приведены в таблицах 2.6 и 2.7.
6. Предложен алгоритм классификации объектов интереса – опухолей (доброкачественных или злокачественных) с использованием разработанного метода сегментации, извлеченных признаков и алгоритма на основе нейронной сети, который позволяет повысить точность диагностики на МРТ и КТ изображениях.

Основные результаты исследований по главе 2 опубликованы в [50, 51, 162, 170, 171, 173, 183-185], а также использовались в [53, 182] для анализа медицинских изображений.

## **ГЛАВА 3. РАЗРАБОТКА МЕТОДИКИ И АЛГОРИТМИЧЕСКОЕ ОБЕСПЕЧЕНИЕ ОБРАБОТКИ И АНАЛИЗА ИЗОБРАЖЕНИЙ**

Третья глава содержит описание разработанной вычислительной методики и алгоритмического обеспечения для извлечения данных из взаимодействующих информационных процессов обработки и анализа визуальных данных в рентгенологии.

Если невозможно получить данные, непосредственно описывающие состояние поврежденного легкого, необходимо изолировать сигнал от не инвазивно полученных источников. Решение этой задачи выполнено с помощью машинного обучения, а разработанное алгоритмическое обеспечение позволило увеличить точность диагностики границы легкого, выделения опухоли и классификации патологий в случае неоднозначности на изображениях компьютерная томография (КТ) и рентгенография грудной клетки (СХR). В этой главе также излагается методика глубокого обучения нейронных сетей и способы ее применения для распознавания патологии на СХR-изображениях. Обнаружение контуров легких и классификация объектов с использованием СХR (обнаружение патологии) на ранней стадии, а также принятие диагностических решений играют важную роль в здоровье человека.

### **3.1. Обзор современных подходов к обработке и анализу изображений СХR и КТ**

В настоящее время заболеваемость органов дыхания занимает лидирующее положение, что ведет к востребованности в радиологических исследованиях. Рентгенограмма грудной клетки до сих пор является наиболее часто используемым методом визуализации для диагностики различных заболеваний легких. А также наиболее широко используемой диагностической визуализацией благодаря ее низкому уровню радиации, отсутствию побочных эффектов, экономической целесообразности и умеренной чувствительности.

Формулировка высокоточных рентгеновских результатов основана на опыте радиолога и качестве рентгеновского снимка. Для большинства болезней многие методы лечения эффективны только на ранней и бессимптомной стадии болезни. Скрининг может помочь в ранней диагностике, а стандартная рентгенография грудной клетки является наиболее популярным методом визуализации по причинам, упомянутым выше [3, 12].

Поиск путей автоматизации диагностики по медицинским изображениям является одним из наиболее перспективным направлением при разработке алгоритмического обеспечения. Для достижения надежной и точной оценки разрабатываются системы компьютерной автоматизированной диагностики (CAD) для содействия интерпретации медицинских изображений.

CAD стала одним из основных объектов исследований в медицинской визуализации и диагностической рентгенологии. Основная концепция построения CAD заключается в предоставлении компьютерного вывода в качестве второго мнения для помощи рентгенологу в интерпретации изображений путем повышения точности и согласованности рентгенологической диагностики, а также путем сокращения времени считывания изображений. Поэтому для разработки успешной CAD системы необходимо не только разработать алгоритмы, но и исследовать, насколько полезен компьютерный выход для рентгенологов в их диагностике.

Также важно количественно оценить ценность компьютерного выхода для рентгенологов, и как максимально увеличить эффект от компьютерного выхода для диагностики [132]. На рисунке 3.1 показана типичная архитектура системы CAD для обеспечения количественного медицинского диагноза.

Важными шагами в автоматическом анализе CXR изображений являются точное определение границ легких и их классификация как нормальных или ненормальных (с патологиями) снимков. Это ранний диагностический инструмент, широко используемый в клинических условиях для мониторинга дефектов в области сердца, в том числе легочных и сердечных заболеваний (кровоизлияний, уплотнений, пневмоторакса, плеврального выпотов, отеков,

увеличения и инфляции сердца) [24]. В некоторых диагностических случаях информация, основанная на непосредственно связанных изображениях границ легких, может быть извлечена без дальнейшего анализа.

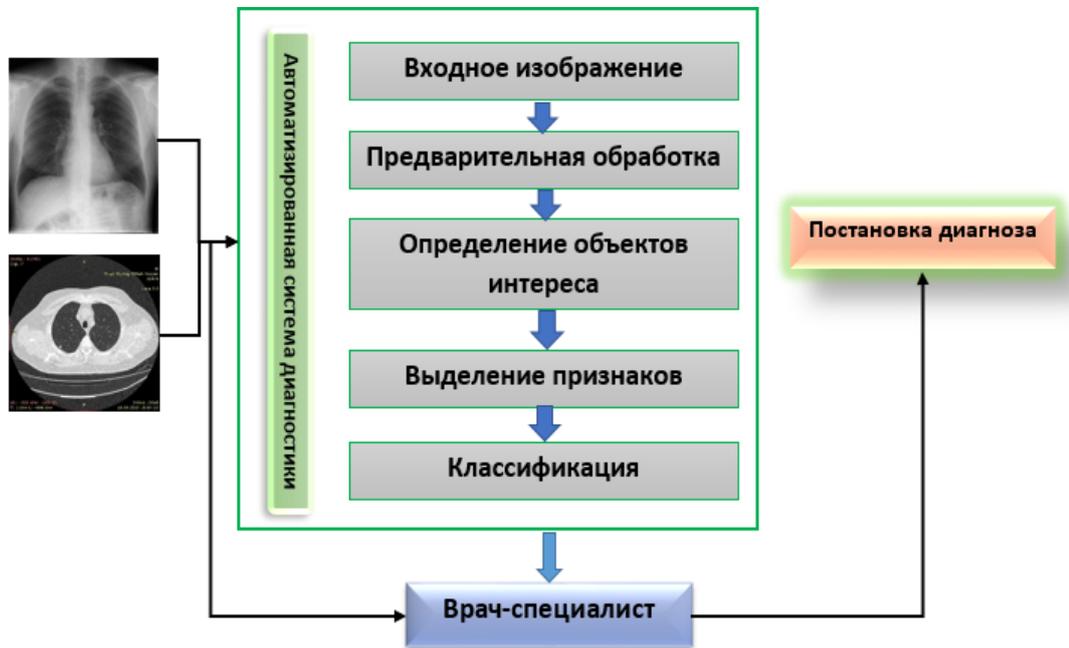


Рисунок 3.1 – Алгоритмическая схема САД обработки и анализа медицинских изображений

Например, наличие нерегулярной формы, изменений объема и общий объем легких [73] свидетельствует о таких серьезных заболеваниях, как увеличение сердца, пневмония или эмфизема [27, 36]. Обнаружение областей, положения и формы легких является важным компонентом, особенно при определении того, является ли легкое нормальным или аномальным [88, 133]. Обнаружение легочной области обычно является первым шагом в компьютеризированном анализе рентгенографии грудной клетки. Информация о геометрии легких позволяет сделать дальнейшие оценки о состоянии легких.

В последние годы рядом исследователей предложены различные методы сегментации CXR-изображений, позволяющие получить границу легких. Эти методы используют различные подходы. Так, можно использовать подход, основанный на правилах, который содержит последовательности шагов и правил, таких как пороговые или морфологические вычислительные операции.

Методы, основанные на этом подходе, основаны на эвристических предположениях и находят приближительные решения. Результаты могут быть использованы как этап инициализации более робастных алгоритмов сегментации [146]. Saad M. предложил метод сегментации области легких в CXR изображениях с использованием хитроумного краевого фильтра и обработки морфологии [113].

Другой более общий подход, рассматривающий классификацию пикселей, состоит в моделировании интенсивности внутри и вне областей легких, и классификации пикселей изображения либо на объект (поле легких), либо на фон. Также разработаны методы, использующие модели формы или внешнего вида легких [75]. Помимо этих общих подходов, исследователи используют комбинацию различных подходов.

Так, Li X. и др. [88] предложили использовать графическую сегментацию с информацией, основанной на функции глобального контраста. Для сегментации легких использовали метод оптимизации графового разреза в сочетании с моделью легких. Кроме того, в качестве признаков они использовали разницу между соответствующими областями в левом и правом легочных полях. Для каждой области создается отдельный учебный комплект, а окончательная классификация проводится путем голосования и взвешенной интеграции.

Методы обработки изображений используются на рентгенограммах грудной клетки также для определения площади легких, измерений размеров и неоднородностей формы [64]. Чтобы отличить нормальные и аномальные (с патологией) CXR изображения используют соответствующий край грудной клетки, сначала определяя область интереса (ROI). В [62] подсистемы текстовых, фокальных и фигурных искажений объединены в одну систему для решения проблемы неоднородности.

Эффективность скрининга на туберкулез (ТБ) и базы данных по туберкулезу открыта с использованием как внешнего, так и радиологического эталонного стандарта. В [143] работа представляет собой способ классификации CXR на две части: с туберкулёзом и без туберкулёза. В зависимости от способа выбора

формы, структура считается выделенной, затем выполняется сегментация и она классифицируется по таким классификаторам как SVM и CNN.

Классификацию изображений ТБ с использованием векторного нейросетевого классификатора в качестве поддержки в [109] предложили как способ обнаружения нормальных и аномальных изображений ТБ. Отмечено также значительное улучшение классификационного разрешения, как на уровне объекта, так и на уровне изображения. С использованием рентгенограмм грудной клетки, анатомического атласа и данных КТ в [25, 114] предложены методы определения границ легких, превосходящие по своим характеристикам усовершенствованные стандартные оценки аномальных форм легких.

Появление цифровой рентгенографии грудной клетки и возможности цифровой обработки изображений придало новый импульс автоматизированному скринингу и диагностике. Тем не менее, несмотря на это в медицинской практике стандартный CXR-анализ является сложным инструментом визуализации. Поэтому для определения наличия патологий (возможных заболеваний) широко используется подход, основанный на использовании искусственных нейронных сетей (ИНС) [61]. Алгоритмы, использующие ИНС, могут достичь самообучения и справиться с меняющимися обстоятельствами. Сегментация легочной области в рентгенограмме грудной клетки (CXR), основанная на обнаружении краев объекта, является одним из широко применяемых методов [115].

## **3.2. Вычислительная методика обработки и анализа снимков**

### **3.2.1. Общая алгоритмическая блок-схема**

Целью исследований в этом разделе является разработка методики и алгоритмического обеспечения для сегментации CXR-изображений, а также классификации их для определения границ легких и выявления аномалий. Также решается задача, как сделать более четкими границы легких, что приведет к лучшей классификации CXR изображений.

Предлагается вычислительная методика, который включает набор вычислительных процедур для обработки изображений и для дальнейшего анализа их медицинскими специалистами. В этих настройках можно выделить две основные составляющие: улучшение качества изображения и формирование границ легких. На втором этапе выполняется классификация СХР-изображений бинарным классификатором ИНС. Алгоритмическое обеспечение реализовано с использованием языка программирования Matlab (Matlab 2017Ra, программные средства).

Наличие патологий на изображениях определяется предложенной вычислительной методикой тремя этапами. В большинстве случаев изображения СХР (или наборы изображений) имеют заметные шумы и различные уровни контраста в связи с техническими характеристиками устройства. Так, на первом этапе проводится подавление шума медианным фильтром и усиление контраста. На втором этапе проводится определение границ легких. Во время этого шага расчеты выполняются по методу Оцу и формируются границы. Третий этап посвящен классификации изображений (обнаружению патологии).

Извлечение функций основано на классификации GLCM, а классификация объектов на СХР производится классификатором конкурентной вероятностной нейронной сети (CPNN). На рисунке 3.2 показана принципиальная алгоритмическая схема предлагаемой методики. Предлагаемая общая алгоритмическая схема, включает основные элементы для обработки и анализа изображений СХР и КТ, которые и отражены на рисунке 3.2.

### 3.2.2. Предварительная обработка рентгенограмм грудной клетки

Основной задачей препроцессинга является улучшение качества объектов интереса на СХР-изображении. Этот вычислительный этап помогает улучшить определенные параметры СХР-изображений (например, соотношение сигнал/шум) и улучшить визуальный вид за счет удаления несущественных шумов и нежелательных частей фона.

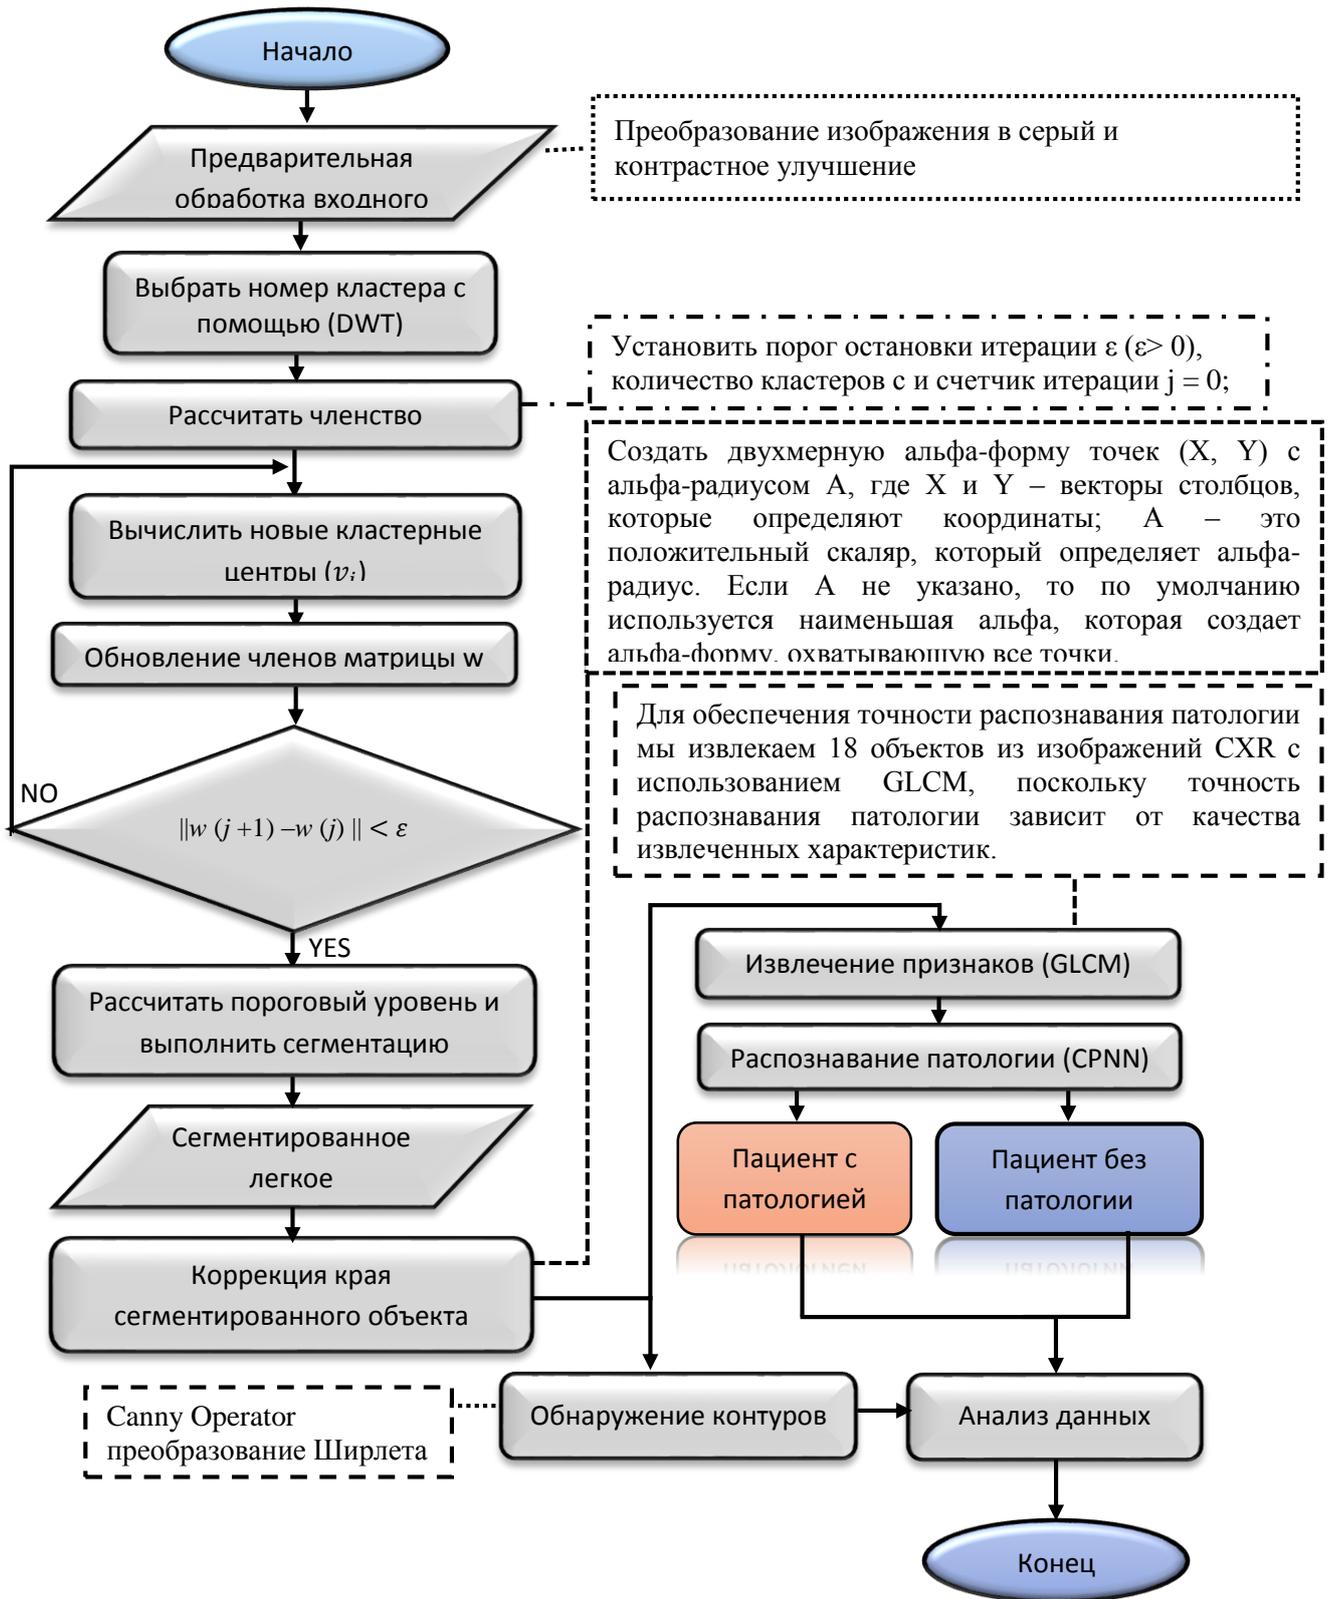


Рисунок 3.2 – Блок-схема алгоритма компьютерной диагностики для анализа CXR изображений

Наиболее часто встречающиеся типы шума – это шум Гаусса и Пуассона. С учетом возможных вариантов шумов на СХР изображениях медианный фильтр выбран в качестве основного фильтра для подавления шумов [62].

Помимо шумоподавления во время обработки медицинских изображений для интересующей области требуется повышение контрастности. В предлагаемой методике используем алгоритм, основанный на методе улучшения баланса контраста (ТПКБ). Выбор сделан потому, что контрастность изображения можно растягивать или сжимать без изменения гистограммы входного изображения [137]. Также другим вариантом является контрастное ограниченное выравнивание адаптивной гистограммы (CALNE) [96].

Для повышения контрастности изображения на рентгеновских снимках грудной клетки использовалась модифицированная методика повышения контрастности баланса (ТПКБ), которая обсуждалась во второй главе в разделе 2.2.1. Результаты повышения контрастности для СХР изображений с патологиями и без них показаны на рисунках 3.3 и 3.4.

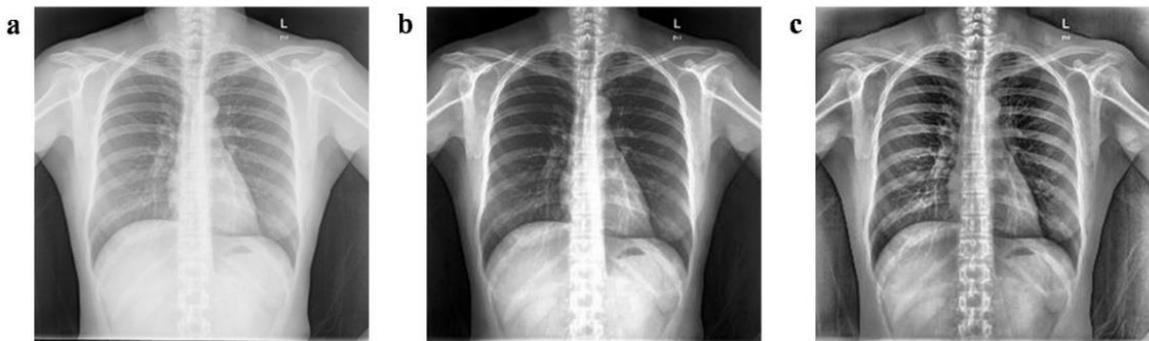


Рисунок 3.3 – а) легкие без патологии; б) усиление ТПКБ; в) усиление CALNE

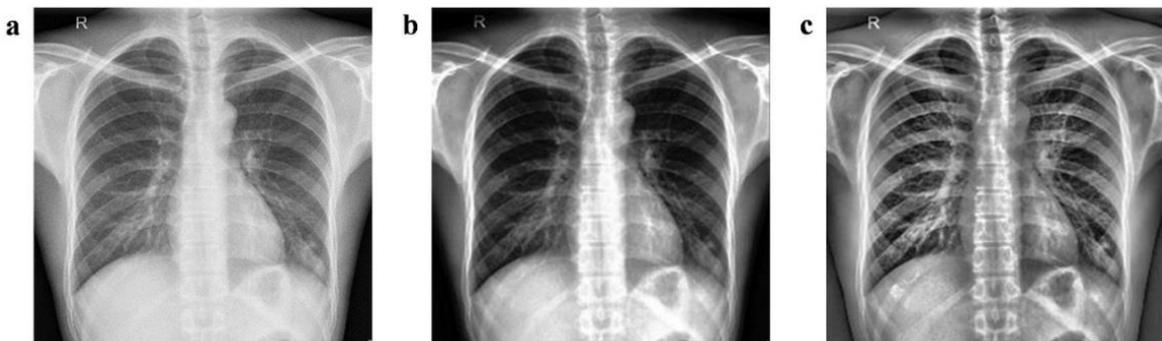


Рисунок 3.4 – а) легкие с патологией; б) усиление ТПКБ; в) усиление CALNE

Как видно, результаты алгоритмом ТПКБ лучше подходят для определения площади легких по сравнению с результатами на основе метода CLANE. Это связано с тем, что область легких темнее, чем на первоначальной снимке, а контраст сосудов, тканей и ребер небольшой. Тем не менее, результаты по методу CLANE могут быть использованы в качестве дополнительных данных для расчета искомым характеристик.

### 3.2.3. Сегментация CXR на основе метода вейвлет-порога

Пороговая сегментация – простой нелинейный метод, который работает по вейвлет-коэффициентам. При этом подходе каждый коэффициент проходит через пороговую функцию. Коэффициенты, которые меньше порога устанавливаются на ноль, и другие – сохраняются или изменяются с учетом метода порогового значения.

В тоже время вейвлет-преобразование хорошо использовать для «энергетического уплотнения», небольшие значения коэффициентов считаются шумовыми, большие значения коэффициентов указывают на важные особенности сигнала [157]. Поэтому эти малые значения коэффициентов можно сократить, поскольку они не влияют на важные особенности изображения.

Сегментация CXR и КТ изображений выполняется в два этапа:

- использование дискретного вейвлет-преобразования для создания автоматического кластера вместо использования статического кластера:

- Двухмерное вейвлет-разложение с использованием B-Spline;
- Оцу порог на каждом из 4 выходов вейвлета;
- Вычисление нового порога из суммы 4 порогов Оцу и деления на 2

$$k = (\text{thresh1} + \text{thresh2} + \text{thresh3} + \text{thresh4})/2;$$

- одноуровневое обратное дискретное двумерное вейвлет-преобразование

$$X = \text{idwt2}(cA, cH, cV, cD),$$

где  $k$  – новый кластер, а  $X$  – новые входные данные.

- Нечеткая кластеризация выполняет кластеризацию путем итеративного поиска набора нечетких кластеров и связанных с ними центров кластеров, которые наилучшим образом представляют структуру данных, но в этом методе, который мы использовали, получен из DWT. Он позволяет разделить существующий набор степеней  $n$  на заданное количество нечетких множеств.

Особенностью метода является использование нечеткой матрицы принадлежности  $W = \{w_{ik}\}$ . Эти элементы определяют степень принадлежности  $k_{th}$  элемента начального набора векторов  $i_{th}$  кластеру. Учитывая количество кластеров  $c$ , кластеризация разделяет данные  $x = \{x_1, x_2, \dots, x_n\}$  в  $c$  нечетких кластеров с центрами кластеров  $V = (v_1, v_2, \dots, v_c)$  путем минимизации целевой функции:

$$F(W, V) = \sum_{i=1}^c \sum_{k=1}^n (w_{ik})^m \cdot \|\mathbf{x}_k - \mathbf{v}_i\|^2, \quad w_{ik} \in [0, 1], \quad i = \overline{1, c}, \quad k = \overline{1, n}, \quad 1 \leq m < \infty, \quad (3.1)$$

где  $m$  – индекс нечеткости,  $w_{ik}$  – степень членства  $x_k$  в  $i_{th}$  кластере,  $v_i$  является центром  $i_{th}$  кластера, а  $\|\mathbf{x}_k - \mathbf{v}_i\|^2$  представляет расстояние между данными  $x_k$  и центром кластера  $v_i$ :

$$w_{ik} = \left( \sum_{j=1}^c \left( \frac{\|\mathbf{x}_k - \mathbf{v}_i\|}{\|\mathbf{x}_k - \mathbf{v}_j\|} \right)^{2/(m-1)} \right)^{-1}, \quad \sum_{i=1}^c w_{ik} = 1, \quad (3.2)$$

$$\mathbf{v}_i = \frac{\sum_{k=1}^n (w_{ik})^m \cdot \mathbf{x}_k}{\sum_{k=1}^n (w_{ik})^m}. \quad (3.3)$$

На каждом итерационном шаге метода нечеткой кластеризации С-средних матрица  $W$  вычисляется по формуле (3.2), а соответствующие центры кластеров – по формуле (3.3). Критерием остановки алгоритма является следующее условие: ошибка, вычисленная по (3.1), ниже заданного порогового значения, или модуль разности ошибок, полученных на настоящей и предыдущей итерациях, ниже заданного порога.

Экспоненциальный вес  $m$  влияет на матрицу степеней принадлежности  $W$ . Чем больше  $m$ , тем конечная матрица  $c$ -разбиения становится более «размазанной», а при  $m \rightarrow \infty$  все объекты принадлежат всем кластерам с одинаковой степенью принадлежности. Экспоненциальный вес позволяет также при формировании координат центров кластеров усилить влияние объектов с большими значениями степеней принадлежности и уменьшить влияние объектов с малыми значениями степеней принадлежности.

Наши исследования показывают, что мягкий пороговый метод более желателен по сравнению с жестким, благодаря лучшим визуальным характеристикам. Жесткий пороговый метод может привести к появлению в изображении некоторых прерывистых точек, и это событие может быть неблагоприятным фактором для выполнения сегментации.

Отметим, что более высокая точность сегментации в медицинской визуализации позволяет более точно идентифицировать тип патологии. Для определения контура границ легкого изображение условно делится на две половины. Затем для обеих половин строится выпуклый контур, чтобы дать набор точек в плоскости.

После этого обе половинки объединяются в одно изображение. Наконец, контурное представление формируется с помощью преобразования. Пример сегментации легких с детектированием границ показан на рисунке 3.4.

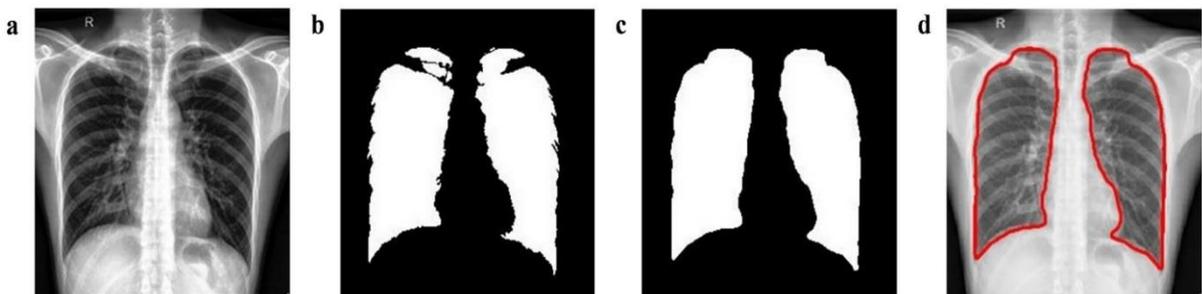


Рисунок 3.4 – а) улучшенное изображение; б) сегментация Оцу; в) выпуклость объекта в точках наружного кольца; д) обнаружены границы легких

Полученные сегментированные CXR-изображения будут полезны при постановке медицинского диагноза врачами-специалистами. Таким образом, информация о легочных сегментах позволяет оценить размер и особенности легких, что может быть полезным для медицинской оценки.

### 3.2.4. Шиарлет-преобразование для обнаружения контуров

Направленное многомасштабное представление изображений для анализа криволинейных сингулярностей получило большое внимание в гармоническом анализе за последние 15 лет. Понятия, связанные с шиарлет-преобразованием, изучаются в работах [90, 114, 140]. Преобразования имеют однородную конструкцию, как для непрерывной, так и для дискретной постановки задачи.

Шиарлеты выделяются еще и тем, что вытекают из представления квадратно-интегрируемых групп и обладают соответствующими полезными математическими свойствами. От непрерывного шиарлет-преобразования можно перейти к дискретному преобразованию, построив дискретную систему сдвига. Для этого необходимо разделить параметры функции на конечный набор дискретных значений и построить систему, которая будет обладать способностью поддерживать свойства непрерывной системы, в том числе, способностью обеспечивать обратное преобразование.

Указанные обстоятельства обеспечивают оптимально разреженное приближение в классе кусочно-гладких функций с кривыми сингулярностями  $C^2$ , т.е. (см. 3.4), где  $f_N$  – такое нелинейное приближение шиарлет-функции  $f$  из этого класса, полученного путем взятия  $N$  наибольших коэффициентов сдвига в абсолютном значении.

$$\|f - f_N\|_{L_2}^2 \leq CN^{-2}(\log N)^3 \text{ при } N \rightarrow \infty. \quad (3.4)$$

Непрерывное шиарлет-преобразование использует матрицу расширения  $A_a$  и матрицу сдвига  $S_s$  для  $d = 2$  и  $\gamma = \frac{1}{2}$ :

$$A_a = \begin{pmatrix} a & 0 \\ 0 & \sqrt{a} \end{pmatrix}, a \in \mathbb{R}^+, S_s = \begin{pmatrix} 1 & s \\ 0 & 1 \end{pmatrix}, s \in \mathbb{R}. \quad (3.5)$$

Шиарлет  $\psi_{a,s,t}$  возникает при расширении, сдвиге и переносе  $\psi \in L_2(\mathbb{R}^2)$  [9, 97, 148]:

$$\psi_{a,s,t}(x) = a^{-\frac{3}{4}}\psi(A_a^{-1}S_s^{-1}(x-t)) = a^{-\frac{3}{4}}\psi\left(\begin{pmatrix} \frac{1}{a} & -\frac{s}{a} \\ 0 & \frac{1}{\sqrt{a}} \end{pmatrix}(x-t)\right). \quad (3.6)$$

Предположим, что  $\widehat{\psi}$  можно записать как уравнение:

$$\widehat{\psi}(\omega_1, \omega_2) = \widehat{\psi}_1(\omega_1)\widehat{\psi}_2\left(\frac{\omega_2}{\omega_1}\right). \quad (3.7)$$

Следовательно, по уравнению 3.8 получаем преобразование Фурье:

$$\begin{aligned} \widehat{\psi}(\omega) &= a^{-\frac{3}{4}}F\left(\psi\left(\begin{pmatrix} \frac{1}{a} & -\frac{s}{a} \\ 0 & \frac{1}{\sqrt{a}} \end{pmatrix}(\cdot-t)\right)\right)(\omega) = \\ &= a^{-\frac{3}{4}}e^{-2\pi i\langle\omega,t\rangle}F\left(\psi\left(\begin{pmatrix} \frac{1}{a} & -\frac{s}{a} \\ 0 & \frac{1}{\sqrt{a}} \end{pmatrix}\cdot\right)\right)(\omega) = \\ &= a^{-\frac{3}{4}}e^{-2\pi i\langle\omega,t\rangle}\left(a^{-\frac{3}{2}}\right)^{-1}\widehat{\psi}\left(\begin{pmatrix} a & 0 \\ s\sqrt{a} & \sqrt{a} \end{pmatrix}\omega\right) = \\ &= a^{\frac{3}{4}}e^{-2\pi i\langle\omega,t\rangle}\widehat{\psi}\left(a\omega_1, \sqrt{a}(s\omega_1 + \omega_2)\right) = a^{\frac{3}{4}}e^{-2\pi i\langle\omega,t\rangle}\widehat{\psi}_1(a\omega_1)\widehat{\psi}_2\left(a^{-\frac{1}{2}}\left(\frac{\omega_2}{\omega_1} + s\right)\right). \quad (3.8) \end{aligned}$$

Шиарлет-преобразование  $SH_\psi(f)$  на  $f \in L_2(\mathbb{R})$  дается как уравнение:

$$\begin{aligned} SH_\psi(f)(a, s, t) &= \langle f, \psi_{a,s,t} \rangle = \langle \widehat{f}, \widehat{\psi}_{a,s,t} \rangle = \int_{\mathbb{R}^2} \widehat{f}(\omega) \overline{\widehat{\psi}_{a,s,t}(\omega)} d\omega = \\ &= a^{\frac{3}{4}} \int_{\mathbb{R}^2} \widehat{f}(\omega) \widehat{\psi}_1(a\omega_1) \widehat{\psi}_2\left(a^{-\frac{1}{2}}\left(\frac{\omega_2}{\omega_1} + s\right)\right) e^{2\pi i\langle\omega,t\rangle} d\omega = \\ &= a^{\frac{3}{4}}F^{-1}\left(\widehat{f}(\omega) \widehat{\psi}_1(a\omega_1) \widehat{\psi}_2\left(a^{-\frac{1}{2}}\left(\frac{\omega_2}{\omega_1} + s\right)\right)\right)(t). \quad (3.9) \end{aligned}$$

Эта же формула выведена путем интерпретации шиарлет-преобразования как свертки с функцией  $\psi_{a,s}(x) = \overline{\psi}(-A_a^{-1}S_s^{-1}x)$ , используя теорему о свертке. Шиарлет-преобразование обратимо, если функция  $\psi$  удовлетворяет свойству допустимости:

$$\int_{\mathbb{R}^2} \frac{|\widehat{\Psi}(v_1, v_2)|}{v_1^2} dv_1 dv_2 < \infty. \quad (3.10)$$

Для расчетов используются две реализации алгоритма шиарлет-преобразования. В [90, 148] представлен алгоритм, называемый «быстрое дискретное шиарлет-преобразование». Он основан на дискретном быстром прямом и обратном преобразовании Фурье. Вейвлет Мейера используется в качестве материнского вейвлета.

Для конечных дискретных цифровых изображений в виде  $\mathbb{R}^{M \times N}$  рассматриваются функции, выбранные в сетке  $\left\{ \left( \frac{m_1}{M}, \frac{m_2}{N} \right) : (m_1, m_2) \in G \right\}$  с  $G := \{(m_1, m_2) : m_1 = 0, \dots, M - 1, m_2 = 0, \dots, N - 1\}$  и предполагается периодическое продолжение через границу.

Дискретное шиарлет-преобразование не только дискретизирует соответствующие параметры  $a$ ,  $s$  и  $t$ , но также учитывает конечное число дискретных трансляций  $t$ . Кроме того, дискретизирует параметр перевода  $t$  на прямоугольной сетке и не зависит от параметра расширения и сдвига  $a$ .

Чтобы получить дискретное шиарлет-преобразование обозначим количество рассматриваемых шкал как  $j_0 := \left\lfloor \frac{1}{2} \log_2 \max\{M, N\} \right\rfloor$ . Затем параметры расширения, сдвига и смещения дискретизируются:

$$a_j = 2^{-2j} = \frac{1}{4^j}, j = 0, \dots, j_0 - 1, \quad (3.11)$$

$$s_{j,k} = k2^{-j}, -2^j \leq k \leq 2^j, \quad (3.12)$$

$$t_m = \left( \frac{m_1}{M}, \frac{m_2}{N} \right), m \in G. \quad (3.13)$$

С этими обозначениями шиарлет определяется уравнением:

$$\Psi_{j,k,m}(x) := \Psi_{a_j, s_{j,k}, t_m}(x) = \Psi(A_{a_j, \frac{1}{2}}^{-1} S_{a_j, k}^{-1}(x - t_m)). \quad (3.14)$$

Альтернативный подход к вычислению шиарлет-преобразования, называемый «ShearLab», описан в [82]. Данная реализация также основана на дискретном быстром преобразовании Фурье; однако этот подход интерпретирует частотный диапазон несколько иначе.

Изучение алгоритма FFST показывает, что контуры объекта могут быть получены как сумма коэффициентов шварц-преобразования для фиксированного масштаба и всех возможных значений параметров сдвига и смещения. В связи с этим предлагается использовать эту особенность при решении задачи для построения контура объекта интереса.

Контуров объектов можно получить как сумму коэффициентов преобразования фиксированных значений параметров для последнего сдвига шкалы и различных значений параметров, как показано в уравнение 3.15, где  $sh_{\psi}$  коэффициент сдвига для шкалы  $j^*$  поворота (ориентации)  $k$  и смещения  $m$ , где  $k_{\max}$  – максимальное число поворотов,  $m_{\max}$  – максимальная величина смещения:

$$f_{cont} = \sum_{k=0}^{k_{\max}} \sum_{m=0}^{m_{\max}} sh_{\psi}(f(j^*, k, m)) \quad (3.15)$$

В качестве количественного параметра для оценки эффективности выполнения алгоритма выбрано среднее время выполнения алгоритмов при решении задач обработки медицинских изображений. При использовании алгоритма Shearlab обработка выполняется быстрее, чем при использовании алгоритма FFST на изображениях больших размеров. Однако алгоритм FFST имеет небольшое преимущество по времени расчета для изображений небольшого размера.

### 3.2.5. Извлечение признаков

Точность классификации зависит от качества извлекаемых свойств. Матрица кооперации уровня серого (GLCM) является надежным способом статистического анализа изображений. Используется для оценки характеристик изображений по статистике второго порядка, детали GLCM объяснены в разделе 1.4.2. Пример графического представления матрицы в методе GLCM для легочных областей показан на рисунке 3.5, для лучшего восприятия матрица GLCM изображена в инвертированных значениях.

Для получения лучших результатов классификации сгенерированы матрицы GLCM для различных смещений (от 2 до 4 пикселей) и углов ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  и  $135^\circ$ ).

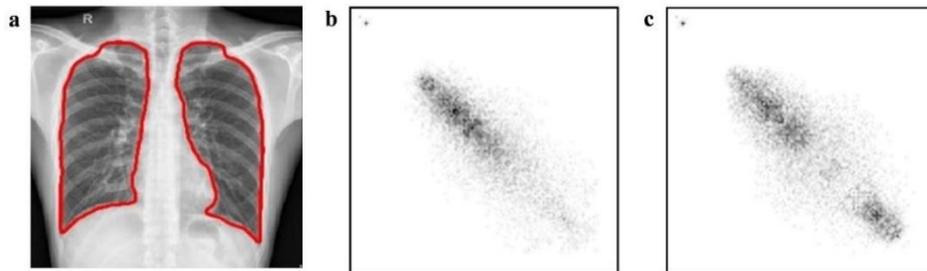


Рисунок 3.5 – а) легочные области; б) представительство GLCM в левом легком; в) представительство GLCM в правом легком

### 3.2.6. Классификация патологии на снимках CXR

Классификатор используется для обнаружения аномальных CXR 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. На рисунках 3.7 и 3.8 подробно описаны архитектура и поток данных в алгоритме CPNN.

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.

Распределение Гаусса  $X_{C_{i,j}}$  в обычном методе PNN равно [171]:

$$W_{ij} = \frac{1}{(2\pi)^{\frac{d}{2}} \sigma^d} * \exp\left(-\frac{(X_{new}-X_{C_{i,j}})^T \cdot (X_{new}-X_{C_{i,j}})}{2\sigma^2}\right), \quad (3.16)$$

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

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

$$C_i = \{X_{C_{i,1}}, X_{C_{i,2}}, \dots, X_{C_{i,|C_i|}}\}. \quad (3.17)$$

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

$$\gamma_i = \frac{NW_i}{|C_i|} \rightarrow NW_i = [\gamma_i |C_i|]. \quad (3.18)$$

Это соотношение  $\gamma_i$  нормализовано и ограничено:

$$\gamma_{i \min} = \frac{1}{|C_i|} \leq \gamma_i \leq 1. \quad (3.19)$$

Отношение  $\gamma_i$  не является непрерывной переменной и может иметь конечное число значений. Используя это обозначение, условно-вероятная вероятность каждого класса в CPNN рассчитывается по формуле:

$$P_i = \frac{1}{NW_i} \sum_{i=1}^{NW_i} W_{ij} = \frac{1}{[\gamma_i |C_i|]} \sum_{j=1}^{[\gamma_i |C_i|]} W_{ij}. \quad (3.20)$$

Традиционный подход PNN можно рассматривать как особую форму CPNN с  $\gamma_i = 1$  для всех классов. Подобно параметру расширения в PNN,  $\sigma$  и параметры  $\gamma_i$  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  $\sigma$

рассматривается как задача верхнего уровня, а оптимизация параметров  $\gamma_i$  рассматривается как задачи нижнего уровня [6]. При оптимизации верхнего уровня предполагается, что все  $\gamma_i$  остаются постоянными и равными единице.

Рассматриваются множественные значения  $\sigma$ , 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  $\sigma$ , параметры  $\gamma_i$  оптимизируются.

В методе CPNN каждый класс имеет свой собственный параметр  $\gamma$ , и каждый параметр класса  $\gamma$  оптимизируется отдельно от  $\gamma$  в других классах. Искусственный набор данных на рисунке 3.6 представляет собой простой набор данных с особенностями, которые являются проблематичными для PNN.

В примере (рисунок 3.6) входные векторы имеют два компонента ( $X_{C_{i,j}} = (x_1, x_2)$ ) и они классифицируются на два класса ( $NC=2$ ). Координаты, расположенные внутри пунктирных линий относятся к классу 2, а оставшаяся область относится к классу 1. Данные о тестировании наносятся на звездочки и квадраты для класса 1 и класса 2, соответственно. Новые входные данные изображены кружком на рисунке 3.6.

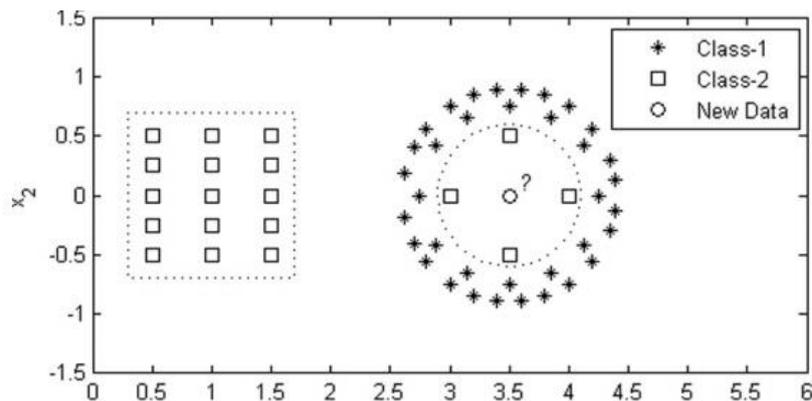


Рисунок 3.6 – Предполагаемые данные обучения и расположение новых входных данных в иллюстративном примере

Архитектура CPNN: ( $X_{new} = (3.5, 0)$ ) должна классифицировать в классы 1 или 2. В этом иллюстративном упражнении данные расположены внутри

пунктирной линии и должны быть классифицированы как класс 2, оптимальное значение, рассчитанное для параметров PNN и CPNN,  $\sigma = 0,5$  и  $\gamma_1 = \gamma_2 = 0,22$ .

Для классификации с использованием алгоритма CPNN, после определения величины всех ядер, сортируются в порядке убывания. Подставляя  $\gamma_1 = \gamma_2 = 0,22$  в формуле (3.18) дает  $NW_1 = 0,22 \times 38 = 8$  и  $NW_2 = 0,22 \times 19 = 4$ . Для расчета апостериорной вероятности в методе CPNN будем использовать 8 и 4 верхних ядра для класса 1 и 2, соответственно.

Алгоритм CPNN дает  $P_1^{CPNN} = 0,2067$  и  $P_2^{PNN} = 0,3861$ , который классифицирует новые входные данные как класс 2 ( $P_{CPNN} < P_1^{CPNN} < P_2^{PNN}$ ). Этот пример представляет случай, в котором метод PNN не может вывести правильный класс, но алгоритм CPNN дает правильную классификацию (рисунки 3.7 - 3.8).

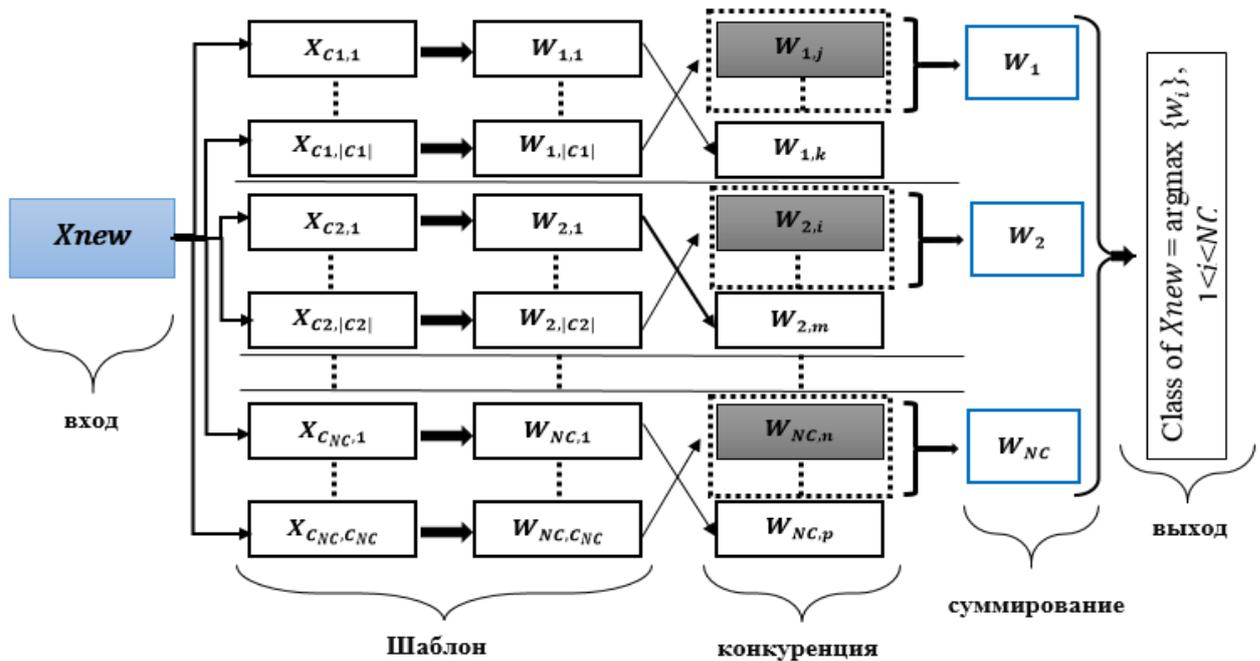


Рисунок 3.7 – Архитектура метода CPNN

В итоге, результатом исследования является разработка усовершенствованного алгоритма обучения для конкурентоспособной вероятностной нейронной сети, которая успешно обучает динамические нейронные сети. Чтобы соблюсти ограничения и решить проблемы с взрывным

ростом веса, введено модифицированное правило для вычисления приращения коэффициента общего веса.

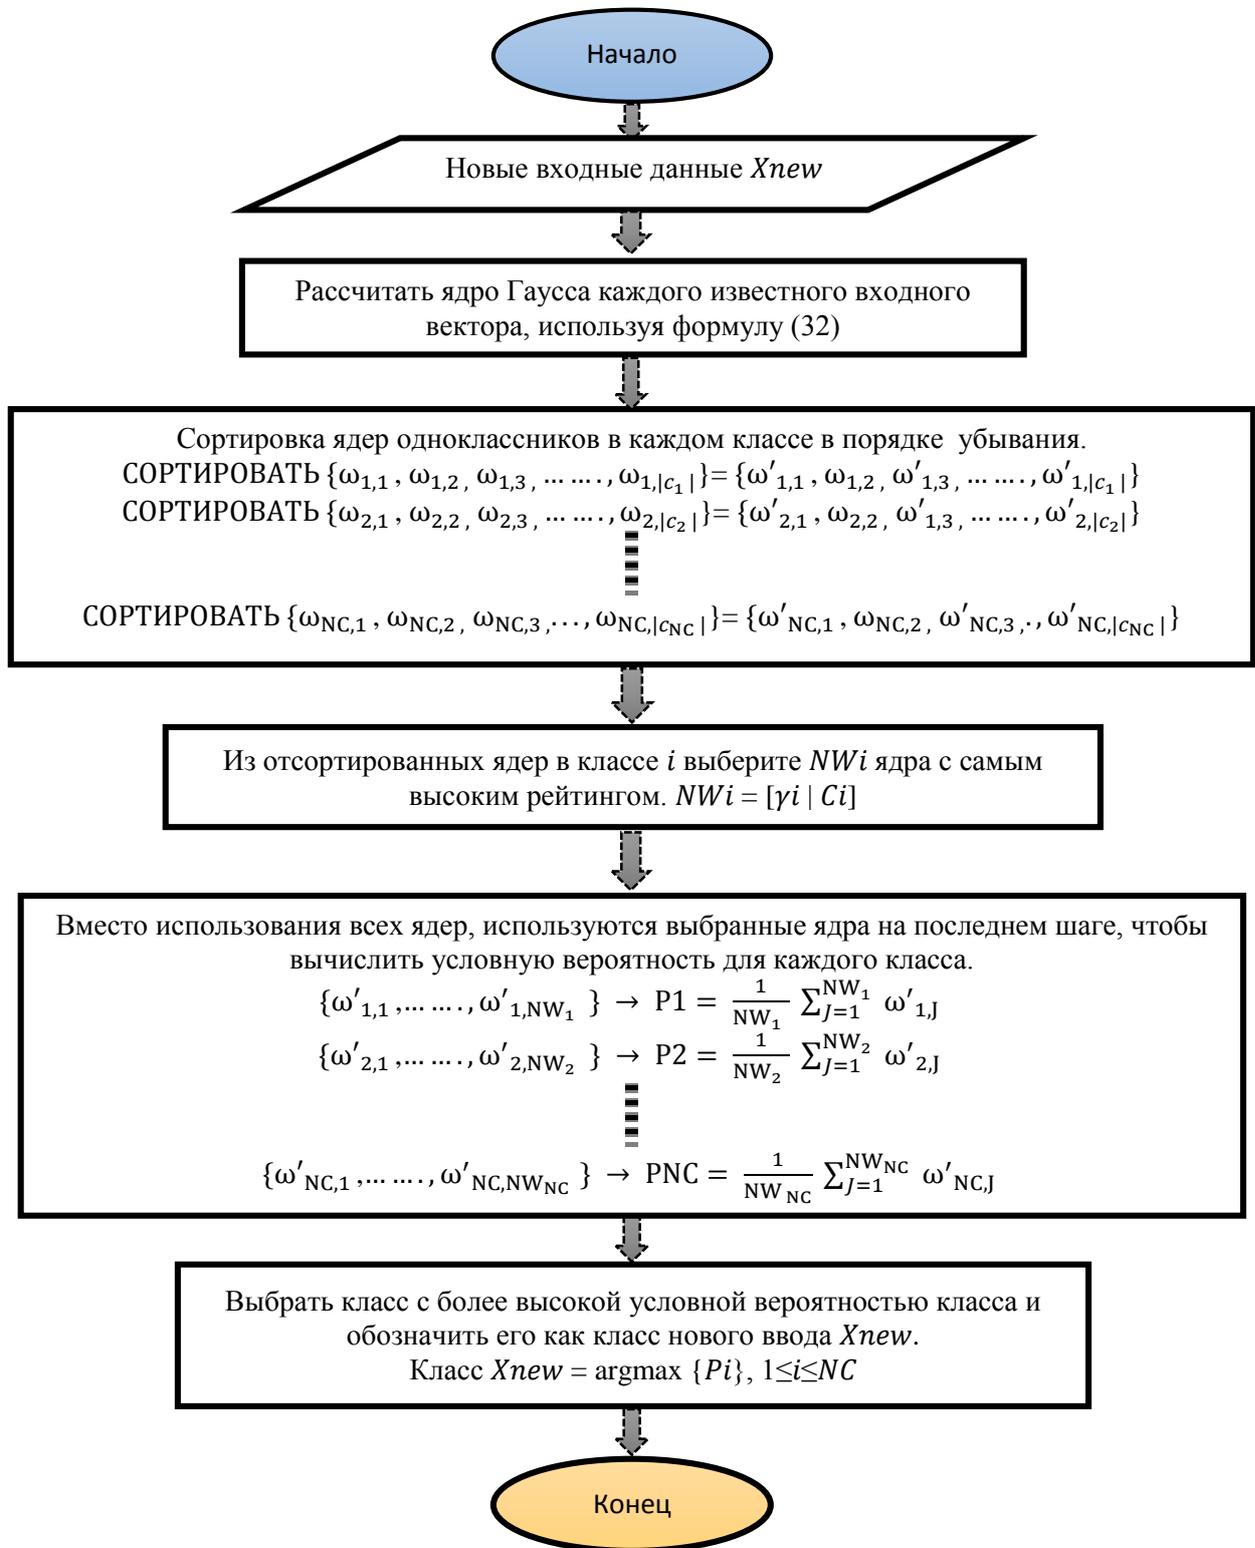


Рисунок 3.8 – Блок-схема разработанного алгоритма CPNN

В этом исследовании разработана вычислительная методика и алгоритмическое обеспечение, которые позволяют создать элементы экспертно-аналитической системы для обнаружения границ легких и классификации изображений CXR, особенно для пациентов с патологией (недоброкачественные новообразования).

Алгоритмы обработки изображений реализованы для решения актуальных задач сегментации и классификации. Предлагаемые алгоритмы для обработки изображений просты в использовании, но играют важную роль в медицинской сфере с точки зрения автоматической сегментации легких на CXR-изображениях. Мотивация разработки новой методики обусловлена отсутствием простых и эффективных вычислительных средств сегментации легких и их классификации. Результаты исследований предполагается внедрить в практическую деятельность специалиста врача-рентгенолога.

Далее, алгоритмическое обеспечение протестировано на многочисленных изображениях, как с патологией, так без патологии, которые собраны из онлайн-баз данных. Задача тестирования – показать способность предлагаемой методики извлекать границы легких в CXR-изображениях, подготавливая их к решению задач сегментации и классификации.

### **3.3. Результаты численных экспериментов**

#### **3.3.1. База данных изображений и расчеты**

Для оценки эффективности предложенной методики проведено разграничение и классификация контура легких рентгеновских снимков для двух различных базах данных.

Базы данных MS и SH, созданные набором MC в Montgomery County и набором SH в Shenzhen Hospital [65], на основе рентгеновских снимков. Набор MC собран в сотрудничестве с Департаментом здравоохранения и социальных служб округа Монтгомери, Мэриленд, США. Набор содержит 138 рентгеновских снимков лобной части грудной клетки по программе скрининга на туберкулез

округа Монтгомери, приведены 80 нормальных случаев и 58 случаев с проявлениями туберкулеза.

Набор SH собран в сотрудничестве с Народной больницей №3 г. Шэньчжэнь и Медицинским колледжем Гуандун, Китай. Набор содержит 662 рентгеновских снимка передней части грудной клетки. Имеется 326 нормальных случаев и 336 случаев с проявлениями туберкулеза.

Рентгеновские снимки предоставляются в форматах PNG и DICOM. Размеры рентгеновских снимков составляют либо  $4020 \times 4892$ , либо  $4892 \times 4020$  пикселей для набора MC и от  $1250 \times 1136$  до  $3000 \times 2989$  пикселей для набора SH.

Целью численного моделирования данных является адаптация и тестирование алгоритмического обеспечения разработанной методики обработки медицинских изображений для сегментации и классификации легкого и в сравнении с другими исследованиями.

В предложенной методике используется определенный набор алгоритмов обработки медицинских изображений. Во-первых, используется сглаживание в виде увеличения контрастности, а также медианная фильтрация. Затем легкие на CXR изображениях сегментируются с помощью порогового значения алгоритма Оцу. Этот подход использовался на основе разницы в интенсивности серого уровня изображения, которые требуют разных пороговых значений для разных изображений. Беспольные связанные пиксели удалены с изображения порога, чтобы сделать его готовым к последнему вычислительному этапу.

Последним шагом в алгоритмической схеме предлагаемой методики является выделение сегментированного легкого и классификация аномалий (обнаружение патологии) с помощью алгоритма CPNN, который является основной частью разработанного алгоритмического обеспечения.

В итоге получаем пороговые изображения, содержащие патологию, и другие легочные структуры, а также другие изображения, содержащие только легочные структуры без патологии. Это непатологическое изображение, которое является чистым, вычтено из пороговых изображений, чтобы извлечь патологию.

При разработке этой методики возникло много проблем. Одной из трудностей является выбор правильной вычислительной схемы для окончательного извлечения и классификации легких на CXR изображениях без извлечения признаков. Поэтому сначала выбраны пороговые значения, при которых для сегментации различных областей изображения используются разные пороговые значения.

Эта вычислительная методика имеет свои преимущества, однако для некоторых изображений легкие не были сегментированы при ее использовании. Кроме того, обнаружено, что некоторые изображения имеют патологию, но на самом деле, это не так, что снижает точность и чувствительность предлагаемой методики. Причиной такой сегментации была разница в интенсивности патологии легких и других участков на изучаемом снимке.

В этой связи в итоговом варианте методики использована пороговая сегментация, при котором порог устанавливается автоматически в зависимости от интенсивности каждого растра, где выделение признаков основано на GLCM, а классификация CXR производится классификатором CPNN.

Далее приведены результаты расчетов и сравнений в виде общей точности определения и классификации границ легких, чувствительности и специфичности. Приведены также оценки в виде коэффициентов сходства Jaccard, коэффициента сходства и среднего расстояния до контура. Значения показателей сведены в таблицы. Также представлены примеры иллюстрирующие процесс работы в соответствии с общей алгоритмической схемой разработанной методики, в результате определяется изображение как нормальное, так и с патологией.

### 3.3.2. Оценка показателей эффективности и точности

Разработанное алгоритмическое обеспечение позволяет сегментировать произвольное изображение грудной клетки и классифицировать его по CXR-снимку, которое содержит множество других компонентов или структур. Поэтому изображения предварительно обрабатывались перед началом процесса

сегментации и классификации. Это позволяет объекту интереса быть выделенным от других компонентов в изображениях, что существенно облегчает сегментирование легких с помощью порогового значения, а также выполнять некоторые другие операции по обработке изображений.

Для тестирования выбирали изображения, содержащие патологию, а также не имеющие патологии. Для оценки эффективности использовано 80 изображений с патологией легких и 50 изображений без патологии. Показатели, которые использованы для оценки разработанной методики, представляли: точность (объяснено во второй главе), а также метрики: Jaccard similarity coefficient ( $\Omega$ ), Dice similarity coefficient (DSC), average contour distance (ACD).

Эти метрики в основном зависят от значений  $TP$ ,  $TN$ ,  $FP$ ,  $FN$  и  $RE_{Cnt}$ , где  $TP$  – количество пикселей, правильно идентифицированных как легочная область;  $TN$  – количество пикселей, правильно детектированных как фон;  $FP$  – количество пикселей, ложно идентифицированных как легочная область, и  $FN$  – количество пикселей, ложно детектированных как фон. Количество опорных краев ( $RE_{Cnt}$ ) представляет собой количество пикселей краев на контрольной карте, созданной экспертами.

Показатель Jaccard Similarity Coefficient представляет собой метрику перекрытия. Это позволяет количественно определить область перекрытия между сегментацией нашим алгоритмом и опорными границами. Коэффициент сходства определяется как:

$$\Omega = \frac{TP}{TP + FP + FN} \cdot \quad (3.21)$$

Показатель Dice Similarity Coefficient является метрикой Dice (similarity coefficient), сформулированной следующим образом:

$$DSC = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \cdot \quad (3.22)$$

Обе эти метрики имеют значение от 0 до 1, где 1 указывает на полностью перекрывающуюся сегментацию. Классификационное значение каждого пикселя оказывает одинаковое влияние на вычисления независимо от их

расстояния до границы отсчета. Поэтому одних перекрывающихся метрик недостаточно для оценки работы алгоритма обнаружения искомой области.

Предлагается использовать основанные на расстояниях дополнительные метрики, такие как ACD (average contour distance) для количественного определения расстояния между эталонной границей легких и оценочной границей. Метрика ACD измеряет минимальное расстояние каждой точки на границе  $S$  до контура  $R$ . Пусть  $s_i$   $i=1, \dots, n_S$  и  $r_j$   $j=1, \dots, n_R$  – точки на обнаруженной алгоритмом границе  $S$  и опорной границе  $R$ , соответственно. Минимальное расстояние точки  $s_i$  по  $S$  до  $R$  определяется как  $d(s_i, R) = \min_j \|r_j - s_i\|$ , а показатель ACD вычисляется следующим образом:

$$ACD(S, R) = \frac{1}{2} \left( \frac{\sum_i d(s_i, R)}{n_S} + \frac{\sum_j d(r_j, S)}{n_R} \right). \quad (3.23)$$

Сравнительный анализ предложенной методики и известных методов основан на коэффициенте сходства Jaccard, коэффициенте сходства Dice и метрике ACD. Результаты анализа представлены в таблице 3.1.

Таблица 3.1 – Количественное сравнение методов определения границ легких.

Авторы	Набор данных	оценки		
		$\Omega$	DSC	ACD
Candemir, S., Jaeger [24]	JSRT	$0.954 \pm 0.015$	$0.967 \pm 0.008$	$1.321 \pm 0.316$
	MC	$0.941 \pm 0.034$	$0.960 \pm 0.018$	$1.599 \pm 0.742$
	India	$0.917 \pm 0.048$	$0.947 \pm 0.025$	$2.567 \pm 1.454$
Li, X. [88]	JSRT	$0.916 \pm 0.024$	-	-
Vajda, S. [143]	JSRT	$0.901 \pm 0.054$	-	-
Candemir, S. [25]	Local CXR	$0.835 \pm 0.004$	-	-
Xiao, X. [153]	LIDC-IDRI	$92.45 \pm 0.031$	$95.03 \pm 0.006$	-
Saad, M. N [113]	Local CXR	$0.805 \pm 0.07$	$0.825 \pm 0.010$	-
Разработанная методика	SH	$0.969 \pm 0.014$	$0.970 \pm 0.012$	$1.715 \pm 0.310$
	MC	$0.950 \pm 0.029$	$0.952 \pm 0.058$	$1.635 \pm 0.323$
	CXR	$0.970 \pm 0.089$	$0.978 \pm 0.021$	$1.989 \pm 0.589$

В таблице 3.2 приведены статистические данные количественных оценок выявленных границ легких. Для расчета оценок объединили наборы данных MC и SH.

Таблица 3.2 – Статистические данные количественных оценок определения границ легких для объединенного набора данных (MC + SH).

Оценки	Статистические данные			
	Минимум	Avg $\pm$ SD	Средний	Максимум
<b><math>\Omega</math></b>	0.952	0.969 $\pm$ 0.016	0.968	0.985
<b>Sens.</b>	0.965	0.964 $\pm$ 0.012	0.967	0.990
<b>Acc.</b>	0.950	0.985 $\pm$ 0.007	0.974	0.996
<b>DSC</b>	0.957	0.975 $\pm$ 0.015	0.970	0.989
<b>ACD</b>	1.247	1.642 $\pm$ 0.323	1.523	2.551
<b>FOM</b>	0.965	0.975 $\pm$ 0.011	0.982	0.998

Для проверки точности классификатора CPNN проведено обучение по совместному набору CXR изображений из наборов данных MC и SH. Учебный комплект содержит 40 CXR изображений с патологиями и 40 CXR изображений без патологий. Точность классификации CPNN отдельно проверена на наборах CXR изображений. Результаты расчетов приведены в таблице 3.3.

Таблица 3.3 – Точность классификатора CPNN для CXR изображений из наборов данных MC и SH.

Изображений	MC Набор данных			SH Набор данных		
	Количество изображений	Классифицировано %		Количество изображений	Классифицировано %	
		Правильно	Неправильно		Правильно	Неправильно
Изображения без патологии	75	96.94	3.06	99	97.89	2.11
Изображения с патологией	50	96.58	3.42	80	95.77	4.23
Общее количество	125	96.76	3.24	179	96.83	3.17

Экспериментальные исследования показали, что средняя точность классификации составляет 96%. Как можно заметить из таблицы 3.3, точность для набора SH выше, чем для набора MC. Ошибка классификация аномальных CXR изображений составляет около 4-5%.

В итоге, в таблице 3.4 приведены данные сравнительного анализа обработки некоторых указанных выше медицинских изображений различными методами и с помощью разработанной вычислительной методики.

Таблица 3.4.– Сравнительный анализ данных обработки медицинских изображений различными методами и с помощью вычислительной методики.

Методы	Метрика PSNR (db)
Алгоритм Превитта (Prewitt)	24.68
Алгоритм Собела (Sobel)	26.25
Алгоритм Fast Finite Shearlet Transform (FFST) – Hauser s., 2013	27.05
Модифицированный алгоритм FFST– Luis Cadena, 2016	33.50
<b>Вычислительная методика – (DWT-FFST-FCM)</b>	<b>34.36</b>

### 3.4. Выводы по третьей главе

Получены следующие результаты.

1. Поставлена и решена задача минимизации отношения объема покрытия к объему покрываемого объекта (легкого) для определения параметров сегментации в виде скопления пикселей и степени их перекрытия.
2. Разработан метод определения дополнительных параметров сегментации (порогового значения), которые важны для автоматической сегментации с использованием дискретного вейвлет-преобразования, что позволяет повысить точность сегментации и обнаружения границ объектов интереса (легких) на 1-2% по сравнению с современными методами определения границ легких на медицинских снимках CXR (2014-2019 гг.), результат показан в таблице 3.1.

3. Предложен модифицированный алгоритм шимлет-преобразования для определения контуров объектов интереса (легких).
4. Разработаны вычислительная методика и алгоритмическое обеспечение обработки и анализа изображений СХР и КТ на основе усовершенствованного алгоритма CPNN и модифицированного алгоритма шимлет-преобразования (FFST) для определения границ легких и распознавания патологий на рентгенограммах грудной клетки, включая обнаружение опухолей на изображениях КТ, которые позволяют повысить точность диагностики. Средняя точность распознавания объектов (патологий) на исследуемых базах данных достигает 96 %.
5. Разработана вычислительная методика для распознавания объектов, включающий в себя дополнительный уровень (конкуренции), который возникает между вычислением гауссовых ядер и условных вероятностей. На рисунках 3.10 и 3.11 описана структура и поток данных в алгоритмической схеме CPNN. Конкурентный уровень вводит два дополнительных этапа, которые включают новые функции для CPNN. На первом этапе значения сортируются и ранжируются в порядке убывания. Все ядра конкурируют за включение в расчет условной вероятности, но используется только часть из них.
6. Вычислительная методика и алгоритмическое обеспечение для обнаружения областей легких дают точность, которая в сочетании с другими подходами (алгоритмами) позволяют достигать хороших соответствий по коэффициентам подобия Жакара и Дайса. Средние значения этих метрик составляют 0,964 и 0,958, соответственно. Средняя точность классификации составляет от 94,98% до 96,77% и зависит от набора данных.

Результаты исследований по третьей главе опубликованы в [52, 163, 174, 180-181, 186], а также использовались в работах [169, 179, 182]

## ГЛАВА 4. ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ

В четвертой главе на основе разработанного способа визуализации и интерпретации данных электронно-сканирующей микроскопии в рамках комплексного медицинского эксперимента решается актуальная задача количественной гистологии: оценка показателей регенерации тканей (размеры зоны прорастания и скорости роста) на имплантатах различного типа.

В качестве вычислительного инструментария для анализа динамики исследуемого процесса регенерации тканей, а также для выделения внутренних геометрических особенностей экспериментальных образов выделяемых объектов, используется модифицированный алгоритм быстрого шиаплет-преобразования FFST (главы 2-3).

Целью численных экспериментов в этой главе является повышение точности анализа экспериментальных визуальных данных (относительно классических подходов) путем модификации современного алгоритмического обеспечения для решения задач количественного морфологического (геометрического) анализа.

Предлагаемый способ содержит предварительную, основную и заключительную стадии обработки исходного снимка. Предварительная стадия обработки исходных изображений предназначена для устранения возможной шумовой составляющей, а также для повышения контрастности и яркости вычисляемых объектов на изображениях для повышения точности в ходе основной стадии численного моделирования данных – геометрического анализа. При этом сравнительный анализ первых вариантов расчета исходных изображений позволяет выделить стандарты различных объектов интереса в изображениях.

В итоге, это позволяет снизить сложность и трудоемкость натуральных экспериментов при анализе динамики роста тканей на имплантатах. А также позволяет более четко визуально разграничить внутренние геометрические особенности объектов интереса на экспериментальных изображениях, тем

самым повышая точность количественных оценок исследуемых показателей и качество их интерпретации. Основные результаты исследований данной главы опубликованы в работах автора [53, 169, 179, 182].

#### **4.1. Постановка задачи в рамках медицинского эксперимента**

В настоящее время использование сетчатых имплантатов широко применяется в различных областях пластической хирургии [74]. В разных странах проводятся исследования по гистологической оценке пригодности различных материалов в качестве имплантатов [35]. Одной из задач современной герниопластики, решаемой с помощью имплантатов, является реконструкция дефектов передней брюшной стенки, т.е. хирургическое лечение дефектов грыжи [22].

Анализ гистологических изображений широко используется также для диагностики различных типов рака [140]. Для этого могут быть использованы цифровые методы обработки изображений, что позволяет ставить более объективные диагнозы. В рамках этой задачи проводятся эксперименты с использованием различных материалов, а также различных методов гистологического анализа тканей, применяются методы сегментации для выявления клеточных структур, свидетельствующих о заболеваниях.

В настоящее время полипропиленовые и политетрафторэтиленовые имплантаты широко применяются. Несмотря на то, что синтетические материалы, представленные на рынке, химически инертны, они не обладают сверхэластичными свойствами, присущими живым тканям. Имплантированные в ткани полимеры вызывают хроническую воспалительную реакцию периферических тканей [168, 175].

В работах [140] показана способность никелированных титановых сеток после имплантации создавать комплекс «живая ткань-имплантат» как единый армированный участок с высокой механической прочностью. Эти имплантаты были созданы исключительно в медицинских целях. Современная технология реконструкции дефектов передней брюшной стенки с использованием

биосовместимых суперэластичных сетчатых имплантатов из никелид титана является актуальной задачей [22]. Ранее проводились многочисленные исследования реакции тканей на имплантацию различных форм (монокристаллических, пористых, ретикулярных) никелид титана при размещении в органах и тканях [63, 99].

Первым этапом сегментации цифровых изображений в области интереса (ROI) обычно является процедура распознавания образов. Процесс сегментации связан с этапом фрагментации или сегментации всего изображения на непересекающиеся и однородные области с целью выявления определенной значимой информации из сегментированных областей, которые обычно считаются однородными по различным критериям, таким как движение, цвет, текстура и т.д., что делает процесс сегментации ведущим этапом в исследованиях, приводящим к обработке изображения [97].

Современный подход в изучении патологии использовался для аннотирования высокоуровневых объектов на микроскопических изображениях, но в основном ориентирован на решение менее сложных задач, называемых микро задачами. Растущее в последнее десятилетие количество полупрозрачных изображений повысило значимость автоматизированных рабочих процессов в связи с ограниченностью времени и доступности патологоанатомов. Сюда относятся средства машинного обучения для определения области интереса, которые позволяют проводить воспроизводимый, объективный и крупномасштабный анализ [87].

В настоящее время проводятся многочисленные исследования в области имплантации с помощью сетчатого никелид титана [86]. В изучаемом эксперименте исследования проводились на кроликах породы шиншилла. Полученный экспериментальный материал подвергался традиционному гистологическому исследованию, а также анализу под электронным сканирующим микроскопом. Количественный гистологический анализ наряду со сканирующей электронной микроскопией используется для анализа тканей

различными исследователями. При этом оценка производится с учетом специфического набора морфологических и морфометрических параметров [21].

Одним из наиболее распространенных решений в качестве вычислительного инструмента для анализа графических данных является вейвлет- и сдвиговое (шиарлет) преобразование [58, 90]. В работах [21, 22] описаны методы комплексной обработки экспериментальных клинических данных. Подход основан на использовании сдвиговых преобразований (шиарлет) и цветового кодирования [164]. Данное решение направлено на уменьшение сложности и трудоемкости натурального эксперимента при анализе динамики роста тканей на имплантатах, а также на формирование более четкого разграничения внутренних геометрических особенностей интересующих объектов в экспериментальных изображениях.

#### **4.2. Сравнительный анализ методов количественной гистологии**

Исследования в области количественной гистологии для оценки пригодности имплантата проводятся с использованием классического гистологического анализа и современных подходов с использованием сканирующей электронной микроскопии. При этом для решения задачи интерпретации измерений, выполненных на срезах, широко используются математические методы [87].

Количественные методы в гистологии направлены на повышение объективности оценки характеристик тканей, разработку новых критериев оценки функции тканей, а также маркеров патологических процессов [121]. Подходы количественного гистологического анализа позволяют найти связь между структурой и функцией тканей при одновременном повышении точности оценок и снижении влияния субъективного фактора на результаты анализа [66]. Это создает условия для алгоритмизации и автоматизации процедуры клинических исследований и диагностики.

Материал, полученный в ходе экспериментального гистологического исследования, должен быть представлен в удобной форме, чтобы медицинский

специалист мог дать правильную оценку. Обычно используют микроскопическую цифровую фотографию окрашенных тканей. Материал (изображения), полученный с помощью сканирующей электронной микроскопии и микроскопической цифровой фотографии, зависит от качества технического оборудования. Довольно часто на цифровых снимках появляются дефекты, вызванные наличием шумов, неравномерным контрастом и низкой яркостью, что, очевидно, снижает качество анализа и точность полученных оценок.

В этой связи первым этапом анализа медицинских снимков является предварительная обработка, направленная на улучшение качества изображения. В рамках предварительной обработки решаются две основные задачи - шумоподавление и настройка яркости (выравнивание) с коррекцией контрастности. Для решения задачи шумоподавления могут использоваться различные фильтры. Проводится множество различных исследований в области шумоподавления медицинских изображений.

В [131] изучались различные медицинские изображения, такие как МРТ, рентген (изображения головного мозга). Авторы опробовали различные медианные базовые методы фильтрации для подавления шума в МРТ и рентгеновских снимках и рекомендовали алгоритм порога с вейвлетами для шумоподавления в ультразвуковых снимках. Усовершенствованный адаптивный метод медианной фильтрации для подавления шумовых импульсов был использован в [69].

В работе [174] изучались различные фильтры, такие как Average (средний), Gaussian, Median и др. для снижения шума в медицинских изображениях, подверженных различным типам нежелательных шумов, однако авторами не было найдено универсального решения. Основываясь на этих данных, П. Канмани и соавт. [98] считают, что медианный фильтр лучше всего подходит для удаления шумов.

Для улучшения контрастности и распределения яркостей исследователи широко использовали методы выравнивания гистограмм как мощный

инструмент препроцессинга [79, 89]. Кроме выравнивания гистограммы для улучшения качества медицинских изображений использовались также алгоритмы на основе Ретинекса [129]. В работе [150] демонстрируется хорошая пригодность алгоритма на основе Ретинекса для улучшения изображений микроскопии.

В рамках анализа изображений необходимо оценить экспериментально особенности прорастающих тканей на имплантате и его окрестностях. Для решения таких задач используются методы геометрического (векторного) анализа изображений. Так, для выделения линейных и нелинейных признаков (края, границы, контуры объектов) могут быть использованы такие методы, как Собель, Превитт, Робертс, Кэнни, Лог [26, 33], а также сдвиговое преобразование [58, 90].

Методы, используемые для выравнивания срезов гистологии, включают глобальные методы на основе пикселей [145], локальные методы поиска [28]. Однако эти подходы предполагают одинаковое оформление всех изображений. Методы, сочетающие сегментацию и регистрацию, находят контуры объектов по методам набора уровней или по порогу [74], формулируют совместный критерий, минимизированный граф GraphCut [10], а регистрацию сегментированных объектов выполняют на основе дескрипторов форм [100].

В работах [14, 176] описаны вычислительные схемы для проведения специальных исследований с использованием конкретных специализированных алгоритмов в качестве решения. Описанные алгоритмы проведения количественного гистологического анализа позволяют эффективно находить зависимости между структурой и функцией тканей, повышать точность оценок, снижать влияние субъективного фактора на результаты анализа, автоматизировать исследовательские и диагностические процедуры.

#### 4.2.1. Описание медицинского эксперимента

Экспериментальные исследования проведены на 39 кроликах породы Шиншилла. Выбор кроликов в качестве подопытных животных обусловлен

наилучшим соответствием биологической реакции тканей животных на имплантацию синтетического материала и реакции тканей человека, и в то же время давал возможность получить достаточное количество биопсийного материала относительно большого размера. Для исследования отобраны животные без внешних признаков заболевания, помещенные в карантин в условиях вивария. В эксперименте участвовали 3 группы сравнения по 11 животных и одна контрольная группа, включавшая 6 животных.

В лабораторном исследовании использовались следующие материалы:

- нить PDS plus представляет собой мононити синтетического рассасывающегося шовного материала, представляющего собой полидиоксаноновую нить, содержащую полидиоксанон и триклозан;

- стандарт "Esfil", представляет собой классический сетчатый эндопротез, изготовленный из мононити полипропилена;

- сетчатый имплантат на основе никелида титана (марка TN-10), обладающий биохимической и биомеханической совместимостью с подвижными анатомическими структурами организма.

Наибольший интерес у медицинских специалистов вызвал эксперимент на группе с использованием имплантата, сотканного по текстильной технологии из сверхэластичной никелид титановой сетки (марки TN-10) размером 5×4 см, толщиной 60 мкм, с размерами ячеек 120-240 мкм.

В рамках гистологического исследования проведен морфологический анализ разреза передней брюшной стенки животного в зоне имплантации трансплантата в группах сравнения. В каждом случае вырезали лоскут передней брюшной стенки полной толщины 1,5×1,5 см с имплантатом и окружающими тканями. Отрезки окрашивали гематоксилин-эозином, серебром, по методу Ван-Гизы и Пикро-Маллори, а затем подвергали анализу с помощью микроскопа Axioskop 40 и цифровой фотокамеры.

Классический подсчет производили на микроскопе при увеличении  $10 \times 1,5 \times 20$  и  $10 \times 15 \times 40$  с помощью окуляра микрометра и сетки с равноудаленными

точками. Для стандартизации данных морфометрию тканевых структур проводили в соответствии с указаниями в [167].

Получены гистоморфометрические показатели тканевых структур в зоне прежних дефектов в краевой, средней и центральной зонах, они суммированы, рассчитано среднее значение. В ходе гистологического исследования оценивали количество клеток соединительной ткани (фибробластов, фиброцитов), клеточных элементов воспалительного ряда, аморфную составляющую, размер сосудов, толщину волокнистых элементов, эластичные и коллагеновые волокна в исследуемой группе и группах сравнения. В качестве отдельного параметра оценивались признаки хронического воспаления – наличие гигантских клеток.

Пример гистологических изображений, полученных на 7-е сутки эксперимента, приведен на рисунке 4.1. На снимках видны изменения в тканях после наложения швов. Ткани окрашивались гематоксилином и эозином.

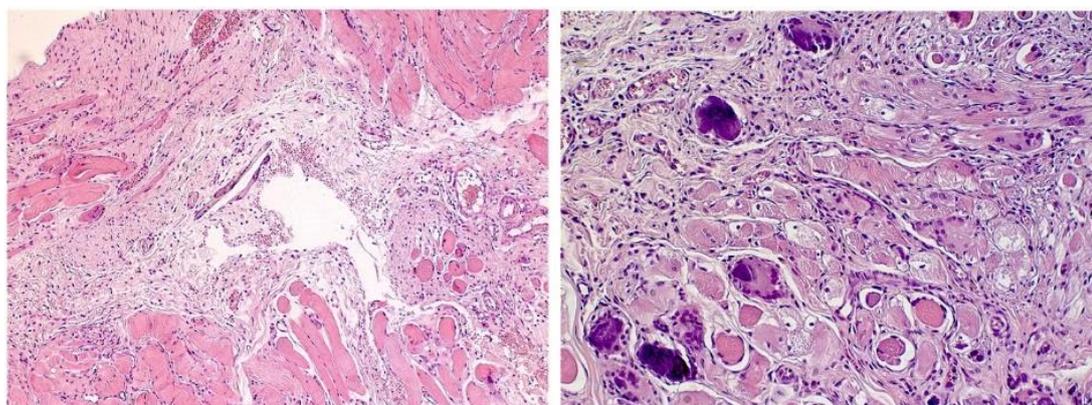


Рисунок 4.1 – Пример гистологических изображений

Подготовка образцов не требовала изготовления ультратонких срезов и окрашивания в трех экспериментальных группах. В III группе никелидно-титановая нить не была удалена из образцов, таким образом, микроскопическая структура не была повреждена. И ориентация коллагеновых волокон, образованных в процессе роста и созревания в пористой структуре никелидно-титанового имплантата, была сохранена.

В рамках оценки данных с использованием электронной микроскопии было проведено исследование фрагментов имплантатов всех трех групп с

использованием сканирующего электронного микроскопа Hitachi TH-3500 в Институте физики имени академ. Л.В. Киренский (Центр коллективного пользования ФИЦ КНЦ СО РАН).

В итоге, определение степени прорастания тканей в сетчатых структурах имплантата на основе никелида титана проводили на электронном микроскопе ТМ 3500 с высоким разрешением до  $\times 30000$  с использованием программного обеспечения QUANTAX 70 EDS.

Примеры изображений, полученных с помощью электронной сканирующей микроскопии, показаны на рисунке 4.2. На рисунке показано прорастание ткани на имплантате на 7-й и 14-й день имплантации. На изображениях видно, что сетчатый имплантат из никелида титана окружен грануляционной тканью. Стрелки указывают: 1 – пучки коллагеновых волокон вокруг имплантата; 2 – эритроциты.

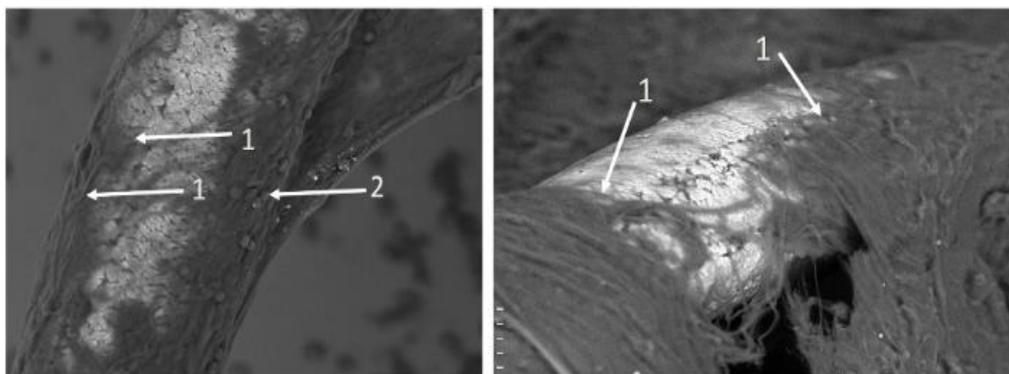


Рисунок 4.2 – Пример изображений электронной сканирующей микроскопии

В случае каждого периода (дня) отбора проб было сделано 10-15 снимков. Это, в свою очередь, значительно увеличило объем работы для исследователей. Наиболее трудоемкой оценкой прорастания тканей на имплантате является расчет площади коллагеновых волокон, количества эритроцитов и др., показателей, демонстрирующих динамику изучаемого процесса. Для ускорения и повышения точности расчетов было решено использовать обработку на основе шпатель-преобразования и контрастирования снимков цветовым кодированием [130, 164].

### 4.3. Способ анализа экспериментальных медицинских изображений

Целью предложенного способа для количественной оценки основных гистологических показателей является повышение точности анализа экспериментальных визуальных данных. Это достигается за счет модификации и адаптации алгоритмической поддержки решения, что позволяет проводить количественный морфологический анализ на основе разработанной методики. Кроме того, данный способ предлагается использовать для оценки показателей изображений, полученных с помощью электронной сканирующей микроскопии.

Здесь за основу взяты разработки [2, 164], где для аппроксимации и спектрального разложения используется алгоритм FFST – дискретное шиарлет-преобразования. Поскольку результаты анализа могут быть подвержены искажениям из-за присутствия шума, возникающего в цифровой матрице, или характера области освещения тестового образца. Мы предлагаем использовать следующие обобщенные этапы для анализа медицинских изображений:

- ✚ Определение деталей, представляющих интерес для исследуемого объекта – структуры, в рамках которой осуществляется определение характеристик эталонных объектов (структурных и текстурных особенностей).
- ✚ Применение предварительной обработки изображения с целью подавления шумов, возникающих в результате формирования изображения, а также для коррекции яркости и локальной контрастности анализируемых изображений.
- ✚ Преобразование изображения в форму, удобную для визуальной интерпретации и дальнейшего анализа. На этом этапе определяются параметры алгоритма вычисления шиарлет-преобразования и карты цветового кодирования.
- ✚ Моделирование расчетных изображений на основе шиарлет-преобразования и определенной шкалы цветового кодирования для

получения оптимальной сегментации и цветовой визуализации конкретных объектов, представляющих интерес.

- ✚ Количественная оценка геометрических, текстурных и морфологических характеристик выбранных объектов интереса для решения поставленной предметной задачи.
- ✚ Сегментация объектов в контурном представлении и формирование карт краев и областей.

Анализ медицинских изображений для клинических экспериментов на имплантатах состоит в выявлении геометрических особенностей текстуры, извлечении волокон и сосудов различного типа и их количественном определении, а также сегментации и контурирование аморфных образований с оценкой их размеров и форм. При оценке роста тканей учитывается также площадь покрытия соответствующего имплантата.

#### 4.3.1. Предварительная обработка: шумоподавление

На этапе предварительной обработки, в качестве первого этапа, выполняется подавление шума, возникающее из-за несовершенства оборудования. Различные фильтры используются для предварительной обработки изображений. Основное назначение этих фильтров – снижение шума, но фильтр также можно использовать для выделения определенных функций изображения или удаления других функций.

Современная обработка изображений включает в себя обработку дискретных или дискретизированных сигналов. Большинство фильтров обработки изображений можно разделить на две основные категории: линейные фильтры и нелинейные фильтры. Выбор фильтра часто определяется характером задачи, а также типом и поведением данных. Шум, динамический диапазон, точность цветопередачи, оптические артефакты и многие другие детали влияют на результат фильтра при обработке изображения.

Медианный фильтр выбран в качестве основного фильтра для подавления шума, поскольку он показывает наилучшую производительность при

подавлении импульсных помех и выполняет обработку, сохраняя четкость границ контрастирующих объектов. Медианный фильтр, как следует из его названия, заменяет значение интенсивности спектра пикселя медианой значений интенсивности спектра в окрестности этого пикселя.

Математически средний фильтр может быть описан уравнением 4.1, где  $I_{new}$  и  $I_{old}$ , – новые и старые значения спектра пикселей изображения, соответственно,  $K_{xy}$  – окно ядра с размерами  $K_{Hs} \times K_{Ws}$  с центром в  $(x, y)$ . Исходное значение пикселя включается в вычисление медианы:

$$I_{new}(x, y) = \underset{(kx, ky) \in K_{xy}}{\text{med}} \{I_{old}(kx, ky)\} \quad (4.1)$$

В качестве вспомогательного фильтра для подавления небольшого аддитивного шума решено использовать оптимизированный по характеристикам гауссов фильтр. Гауссов фильтр – это сверточный фильтр, в котором вычисления проводятся в соответствии с уравнением 4.2, где  $G$  – функция Гаусса.  $RH$  и  $RW$  – константы, определяющие ранг фильтра по вертикали и по горизонтали, соответственно:

$$I_{new}(x, y) = \sum_{dy=-RH}^{RH} \sum_{dx=-RW}^{RW} G(dx, dy) \times I_{old}(x + dx, y + dy) \quad (4.2)$$

Уравнение функции Гаусса в одном измерении (уравнение 4.3) и в двух измерениях, это произведение двух таких гауссианов по одному в каждом измерении (уравнение 4.4), где  $x$  – расстояние от начала координат по горизонтальной оси,  $y$  – расстояние от начала координат по вертикальной оси, а  $\sigma$  – стандартное отклонение распределения Гаусса:

$$G(x) = \frac{1}{\sqrt{2\pi} \cdot \sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (4.3)$$

$$G(x, y) = \frac{1}{2\pi \cdot \sigma^2} e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (4.4)$$

Свертка может быть выполнена довольно быстро, потому что уравнение для двумерного изотропного гауссова делится на компоненты  $y$  и  $x$  [23].

Следовательно, вместо одной двумерной свертки можно применять две одномерные свертки (в строках и столбцах).

#### 4.3.2 Коррекция яркости с контрастным усилением

Медицинские изображения могут иметь различные характеристики яркости в зависимости от условий съемки. Например, серия изображений может иметь низкую или высокую яркость и контрастность. В предлагаемом способе для улучшения качества изображения решено использовать модификацию Multi-Scale Retinex (MSR) в цветовом пространстве HSV, в которой вейвлет-преобразование использовалось для ускорения расчетов [165].

В результате применения вейвлет-преобразования к изображению четыре области LL HL, LH и HH формируются путем чередования одномерного вейвлет-преобразования строк и столбцов. Для расчета скорректированных значений яркости с помощью алгоритма MSR используется область LL, а затем выполняется обратное вейвлет-преобразование. Во время обратного преобразования высокочастотные компоненты (детализация) могут дополнительно увеличивать уровень локального контраста.

Контроль контрастности (уменьшение или увеличение) возможен благодаря использованию двух коэффициентов коррекции интенсивности высокочастотных компонентов. Первый коэффициент ( $k_{div}$ ) отвечает за равномерную коррекцию значений, а второй ( $k_h$ ) позволяет проводить линейную коррекцию в случае превышения локального порога контрастности ( $T_H$ ).

Чтобы уменьшить вычислительную сложность в программной реализации вейвлет-преобразования, решено использовать таблицу соответствия (LUT), которая формируется в соответствии с уравнением 4.5. В этом случае компонент детализации (H) при обработке одномерного дискретного сигнала  $S = \{s_j\}_{j \in Z}$  будет формироваться в зависимости от разности соседних пикселей ( $S_{2j} - S_{2j+1}$ ) с использованием уравнения 4.6. Следует отметить, что обратное вейвлет-преобразование остается неизменным [176].

$$H_{LUT}(i) = \begin{cases} \frac{i}{k_{div}} & \text{if } i \leq T_H \\ \frac{(i - T_H) \cdot k_h + T_H}{k_{div}} & \text{if } i > T_H \end{cases} \quad (4.5)$$

$$H_j = \text{sgn}(S_{2j} - S_{2j+1}) \cdot H_{LUT}(|S_{2j} - S_{2j+1}|) \quad (4.6)$$

Реакция функции MSR ( $R_{MSR}$ ) обычно дает как отрицательные, так и положительные значения, а полученные пределы диапазона будут произвольными. Учитывая это, необходимо преобразовать полученные значения в отображаемую область, т.е. диапазон интенсивности  $[0, 255]$ .

В зависимости от исходного изображения в распределении выходных значений функции MSR среднее значение может быть смещено относительно нуля. Поэтому для формирования выходного изображения принято решение использовать растяжение диапазона с учетом адаптивной настройки степени растяжения. Настройка основана на граничных порогах с учетом желаемого размера диапазона ( $Pr$ ) и сдвига центра распределения (выравнивание с нулем). Расчет выходного значения яркости изображения ( $I_{MSR}$ ) пикселя с заданным диапазоном визуализации ( $I_{TR}$ ) проводится с помощью уравнения 4.7:

$$I_{MSR}(x, y, \sigma) = Cl\left(\frac{R_{MSR}(x, y, \sigma) - \text{avg}(R_{MSR}(\sigma))}{(\max(R_{MSR}(\sigma)) - \min(R_{MSR}(\sigma))) \cdot Pr} \cdot I_{TR} + k_{offset}\right) \quad (4.7)$$

где  $k_{offset}$  – коэффициент смещения яркости, по умолчанию  $k_{offset} = 127$ ;  $Cl()$  – функция отсечки значений за пределами желаемого диапазона.

Пример улучшения качества одного изображения из набора растровых микроскопических изображений с использованием модифицированного алгоритма Multi-Scale Retinex показан на рисунке 4.3. На обработанном изображении можно наблюдать более четкое визуальное разделение титанового имплантата и тканей (коллагеновых волокон, эритроцитов и т.д.).

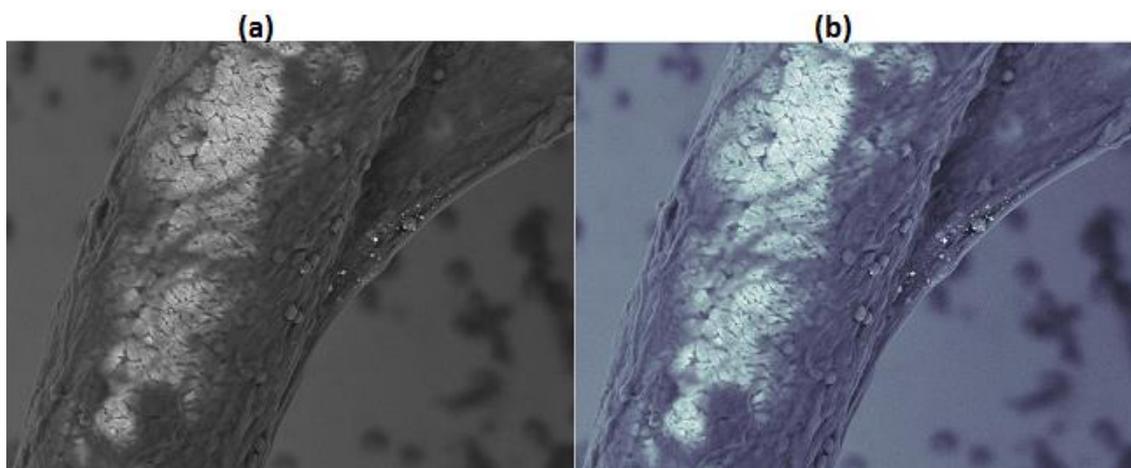


Рисунок 4.3 – Пример обработки изображения алгоритмом Retinex:  
 а) исходное изображение; б) изображение, обработанное  
 модифицированным алгоритмом Retinex

#### 4.3.3. Формирование контурного представления

Контурное представление может быть сгенерировано с использованием разных алгоритмов. Мы можем использовать классические простые методы, такие как Робертс, Prewitt, Sobel и более сложные, например, Canny и LoG [26]. При этом 2D функция LoG с центром в нуле и со стандартным отклонением Гаусса  $\sigma$  имеет вид:

$$LoG(x, y) = -\frac{1}{\pi \cdot \sigma^2} \left[ 1 - \frac{x^2 + y^2}{2\sigma^2} \right] e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (4.8)$$

Алгоритм Кэнни для определения контура использует следующие шаги: сглаживание изображения; поиск градиентов; подавление «ложных» пиков; двойная пороговая фильтрация (потенциальные контуры определяются пороговыми значениями); прослеживая область двусмысленности.

Использование этих методов в зависимости от исходного изображения может давать разные результаты, и в большинстве случаев для более успешного анализа потребуется дополнительная обработка представления контура. Исследование показало, что шпирлет-преобразование обеспечивает более эффективный способ описания характеристик элементов изображения на основе

аффинных преобразований. Ширлеты обладают однородной конструкцией, как для непрерывной, так и для дискретной настройки. Кроме того, они выделяются, поскольку они основаны на квадратично интегрируемом представлении группы и имеют соответствующие полезные математические свойства.

Шиарлет функция ( $\Psi_{a,s,t}$ ) генерируется расширением, сдвигом и переводом функции  $\Psi \in L_2(\mathbb{R}^2)$ , называемой материнской шиарлетом, следующим образом:

$$\Psi_{a,s,t}(x) = a^{-\frac{3}{4}} \Psi(A_a^{-1} S_s^{-1}(x-t)), \quad (4.9)$$

где  $t \in \mathbb{R}^2$  – трансляция  $A_a$  – матрица масштабирования, или расширения, и матрица сдвига  $S_s$ , определенные, в соответствии с уравнением:

$$A_a = \begin{pmatrix} a & 0 \\ 0 & \sqrt{a} \end{pmatrix}, \quad a \in \mathbb{R}^+, \quad S_s = \begin{pmatrix} 1 & s \\ 0 & 1 \end{pmatrix}, \quad s \in \mathbb{R}, \quad (4.10)$$

где  $a \in \mathbb{R}^+$  и  $s \in \mathbb{R}$ .

Анизотропная дилатация  $A_a$  контролирует масштаб, применяя различный коэффициент дилатации вдоль двух осей. Матрица сдвига  $S_s$ , не расширяющаяся, определяет ориентацию. Коэффициент нормализации  $a^{-3/4}$  гарантирует, что  $\|\Psi_{a,s,t}\| = \|\Psi\|$ , где  $\|\Psi\|$  является нормой в  $L^2(\mathbb{R}^2)$ . В классической постановке предполагается, что материнский шиарлет разлагается в области Фурье как:

$$\hat{\Psi}(\omega_1, \omega_2) = \hat{\Psi}_1(\omega_1) \hat{\Psi}_2\left(\frac{\omega_2}{\omega_1}\right), \quad (4.11)$$

где  $\hat{\Psi}$  – преобразование Фурье  $\Psi$ , – одномерный вейвлет и  $\hat{\Psi}_1$  – любая ненулевая квадратично-интегрируемая функция.

Шиарлет-преобразование  $SH(f)$  сигнала  $f \in L^2(\mathbb{R}^2)$  определяется уравнением, где  $\langle f, \Psi_{a,s,t} \rangle$  скалярное произведение в  $L^2(\mathbb{R}^2)$ :

$$SH(f)(a, s, t) = \langle f, \Psi_{a,s,t} \rangle. \quad (4.12)$$

Для расчетов с шиарлет-преобразованием используется алгоритм, называемый «Быстрое дискретное шиарлет-преобразование», представленный в [9, 32]. Он основан на дискретном быстром прямом и обратном преобразовании Фурье. Вейвлет Мейера используется для настоящей реализации в качестве

материнского вейвлета. Для конечных дискретных последовательностей цифровые изображения в  $\mathbb{R}^{M \times N}$  рассматриваются как функции, выбранные в сетке. Дискретное шиарлет-преобразование не только дискретизирует соответствующие параметры  $a$ ,  $s$  и  $t$ , но также учитывает конечное число дискретных трансляций  $t$ . Кроме того, дискретизирует параметр перевода  $t$  на прямоугольной сетке и не зависит от параметра расширения и сдвига.

Чтобы получить дискретное шиарлет-преобразование, обозначим количество рассматриваемых шкал как  $j_0 = \lceil \frac{1}{2} \log_2 \max\{M, N\} \rceil$ . Затем параметры расширения, сдвига дискретизируются:

$$a_j = 2^{-2j} = \frac{1}{4^j}, \quad j = 0, \dots, j_0 - 1, \quad (4.13)$$

$$s_{j,k} = k2^{-j} = \frac{k}{4^j}, \quad -2^j \leq k \leq 2^j, \quad (4.14)$$

$$t_m = \left( \frac{m_1}{M}, \frac{m_2}{N} \right), \quad m \in G, \quad (4.15)$$

$$G = \{(m_1, m_2) : m_1 = 0, \dots, M-1, m_2 = 0, \dots, N-1\}. \quad (4.16)$$

С этими обозначениями шиарлет определяется в виде:

$$\Psi_{j,k,m}(x) := \Psi_{a_j, s_{j,k}, t_m}(x) = \Psi \left( A_{a_j, \frac{1}{2}}^{-1} S_{s_{j,k}}^{-1}(x-t) \right). \quad (4.17)$$

Дискретное шиарлет-преобразование теперь определяется как:

$$SH(f)(j, k, m) = \langle f, \Psi_{j,k,m} \rangle \quad (4.18)$$

Изучение алгоритма FFST показывает, что контуры объекта могут быть получены как сумма коэффициентов шиарлет-преобразования для фиксированного масштаба и всех возможных значений параметров сдвига и смещения. В связи с этим предлагается использовать эту особенность при решении данной задачи аппроксимации.

Контуров объектов могут быть получены как сумма коэффициентов шиарлет-преобразования с фиксированными значениями параметров для последнего сдвига шкалы и различными значениями параметров, как показано в формуле 4.19, где  $SH\Psi$  – коэффициент сдвига для шкалы  $j^*$ , поворота

(ориентации)  $k$  и смещения  $m$ , где  $k_{\max}$  – максимальное число поворотов,  $m_{\max}$  – максимальная величина смещения.

$$f_{cont} = \sum_{k=0}^{k_{\max}} \sum_{m=0}^{m_{\max}} SH_{\psi}(f(j^*, k, m)) \quad (4.19)$$

Альтернативный подход к вычислению шиаплет-преобразования, называемый ShearLab, описан в [156, 164].

#### 4.3.4. Цветовое кодирование объектов на изображении

Чтобы лучше понять представленные медицинские данные и упростить дальнейший анализ, предлагается использовать метод контрастирования медицинских изображений, основанный на цветовом кодировании. Этот метод позволяет привлечь внимание медицинских специалистов к определенным областям анализируемого изображения. Одновременно проводится подготовка к дальнейшему анализу, в ходе которого решаются задачи, необходимые для количественной гистологии.

Для цветового кодирования (выбор цветов и распределение плотности контуров в изображении) используется алгоритмическая процедура с применением метода построения упругой карты из пространственных данных [164]. Предполагается, что анализируемый объект представляет собой ограниченное двумерное многообразие, встроенное в набор изучаемых данных. В этом случае карта объекта является частью поверхности, расположенной внутри облака данных анализируемого изображения.

Рассмотрим двумерную прямоугольную сетку узлов, где  $p$  узлов расположены по горизонтали и  $q$  по вертикали. Узлы сетки будут перечислены с использованием двух индексов  $y_{i,j}$ ,  $i=1, \dots, p$   $j=1, \dots, q$ . Построенная сетка располагается в наборе точек данных таким образом, чтобы каждая точка была связана с ближайшим узлом сетки. Точки данных имеют форму  $t_{i,j}(x, y, M)$ , где  $(x, y)$  – их относительные координаты,  $M$  – интенсивность (цвет), характеризующая особенности исследуемого объекта.

Такой метод позволяет разделить набор данных на подмножества  $pq$   $K_{i,j}$ , причем подмножества точек находятся ближе  $y_{i,j}$ , чем к любому другому узлу. Пусть  $K_{i,j}$  будет как в уравнении:

$$K_{i,j} = \left\{ t \mid t \in P_k, \|y_{i,j} - t\|^2 \leq \varepsilon \right\} \quad (4.20)$$

В случае использования евклидовой метрики функционал  $D$  (функционал качества) является квадратичным по положению узлов  $y_{i,j}$ . Это означает, что с данным набором точек данных, разбитых на таксоны, необходимо решить систему линейных уравнений  $pq \times pq$  для ее минимизации. Следует отметить, что реализация вычислительной схемы учитывает символ плоского изображения, поэтому функционал  $D$  в качестве меры близости сетки к точке данных в упрощенной форме может быть представлен уравнением 4.21, где  $|P_k|$  это количество точек в ячейке:

$$D = \frac{\sum_{i,j} \sum_{t_n \in K_{i,j}} \|t_n - y_{i,j}\|^2}{|P_k|} \rightarrow \min \quad (4.21)$$

В обобщенном виде алгоритм может быть представлен следующим образом:

1. Узлы сетки в любом случае расположены в пространстве данных.
2. Учитывая положение узлов сетки, набор данных разбивается на таксоны - подмножества  $K_{i,j}$ .
3. При заданном разбиении набора точек данных на таксоны функционал  $D$  минимизируется.
4. Шаги 2 и 3 повторяются до тех пор, пока функционал  $D$  не перестанет заметно изменяться.

В рамках реализации цветового кодирования представляющий интерес объект определяется как начальная (центральная) часть построения сетки, относительно которой формируются существенные изолинии. В результате формируется карта, которая дополнительно окрашивается в соответствии с физическим атрибутом для изучаемых данных.

Пример визуальных данных, сгенерированных во время применения предлагаемого способа с использованием цветового кодирования по схеме

«Cool», показан на рисунке 4.4. На рисунке 4.4 показаны два представления результатов обработки медицинских изображений. Они представлены в виде цветных контуров и заполненных областей исследуемых визуальных данных. Окончательным результатом обработки изображения является четкий выбор, как нитей самого имплантата, так и характеристик прорастания тканей на нем.

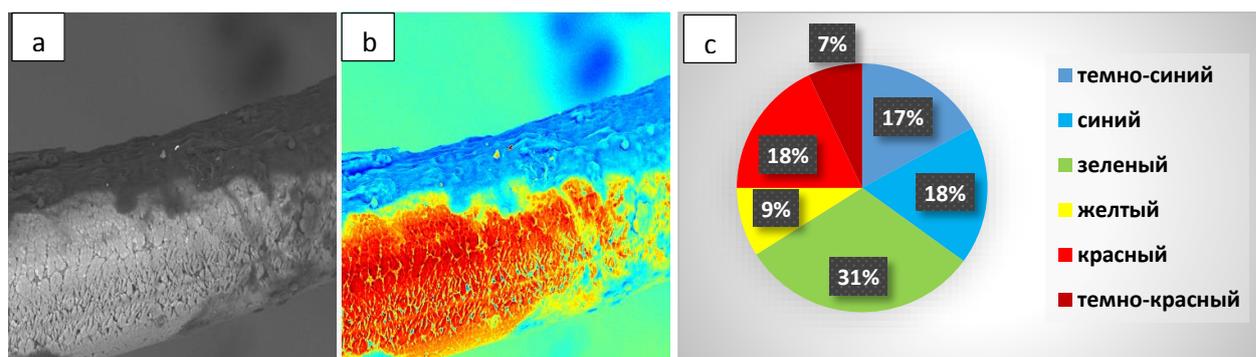


Рисунок 4.4. – Пример цветовой кодировки изображения:

- a) исходное изображение; b) семантическая сегментация области имплантата;  
c) количество пикселей для определения характеристик прорастания тканей

#### 4.3.5. Сегментация экспериментальных изображений

Более высокая точность сегментации в медицинской визуализации позволяет более точно идентифицировать заболевание. Сегментация – это процесс, при котором изображение делится на различные области. Позволяет отобразить всю область изображения с помощью процесса сегментации  $S$ .

Сегментацию  $S$  можно рассматривать как  $S$ -раздел на суб-области, такие как  $S_1, S_2, S_3 \dots S_p$ . Некоторые условия, такие как хэш, должны быть действительны; это означает, что каждый пиксель должен быть внутри области. Все точки в областях должны быть каким-то образом связаны, области должны быть отдельными и т.д.

Площадь произрастания – это совокупность пикселей или суб-области в более крупных областях на основе определенных критериев. Основной задачей

было выявить нити точек области имплантата и присоединить каждую из этих нитей области имплантата к тем смежным пикселям, которые имеют характеристики, схожие с характеристиками области имплантата. Группа нитей самой области имплантата и характеристики роста тканей принимались за входные данные изображения и отмечались как фрагментированные объекты. Область растет за счет оценки всех смежных не присвоенных пикселей в данной области.

Сходство является мерой различия между значением интенсивности пикселей и средней площадью. Пикселю присваивается небольшая разница, измеряемая для соответствующей области. Это происходит до тех пор, пока все пикселы не будут назначены для этой области. Результаты зависят от выбора ячеек.

Пример сегментации области нитей имплантата и характеристики роста тканей на нем с определением границ показан на рисунке 4.5.

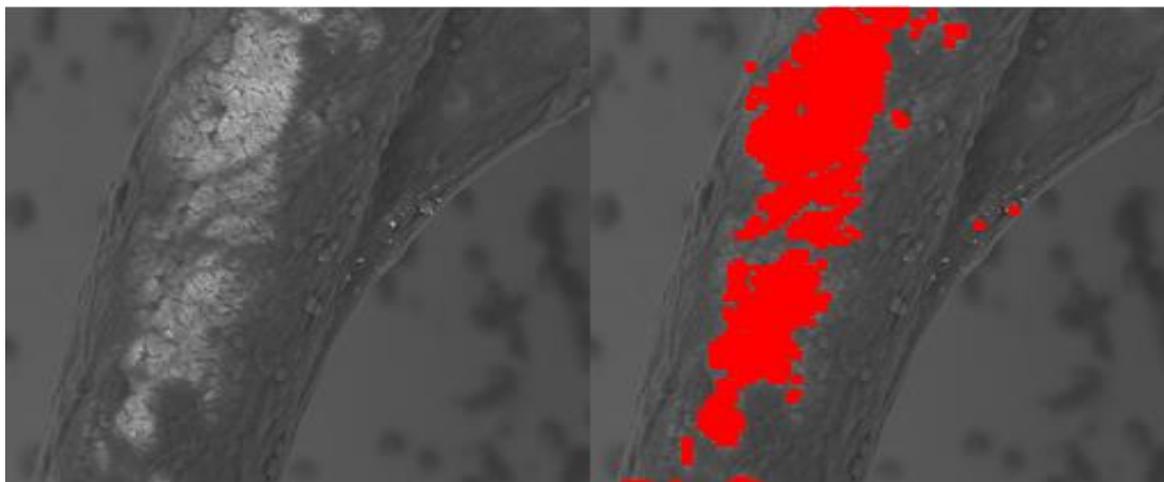


Рисунок 4.5. – а) исходное изображение, б) семантическая сегментация нитей области имплантата (определения характеристик прорастания тканей)

Измерение проводилось на основе средней интенсивности пикселей. Изображение фрагментировано и это изображение использовано для определения желаемой области. И, наконец, преобразование нити области имплантата в красный цвет для большей ясности, используя функцию `Img = imoverlay (Original, SegImag, colors)` в MATLAB 2016b.

Полученные сегментированные гистологические изображения будут полезны при постановке медицинского диагноза врачами-специалистами. Таким образом, информация о сегментах гистологических изображений позволяет оценить размер и особенностей области имплантата, которые могут быть полезны для медицинской оценки.

#### **4.4. Результаты экспериментальных исследований**

Оценка эффективности предложенного способа проводилась с использованием данных, полученных в ходе медицинских опытов на кроликах породы Шиншила, которые проводились на кафедре хирургии Красноярского государственного медицинского университета имени В.Ф. Войно-Ясенецкого.

Целью медицинского эксперимента являлось выявление особенностей тканевой реакции в зависимости от материала, используемого при одном и том же методе реализации. Медицинский эксперимент направлен на выявление особенностей тканевой реакции в зависимости от материала, используемого с тем же методом имплантации.

##### **4.4.1. Описание экспериментальных медицинских данных**

В ходе медицинских экспериментальных исследований получены гистологические данные для анализа, а также изображения сканирующей электронной микроскопии. Для оценки предлагаемой методики взято более 40 гистологических изображений, позволяющих оценить морфологические изменения тканей в зоне имплантации. Полученные изображения имеют разное разрешение, которое варьируется от  $1292 \times 968$  до  $3264 \times 2448$  пикселей. В рамках гистологического исследования срез передней брюшной стенки животного в зоне имплантации трансплантата в группах сравнения подвергался морфологическому анализу.

Примеры изображений, полученных в разные дни проведения медицинского эксперимента, показаны на рисунке 4.6. Они демонстрируют гистологические данные, характеризующие изменение тканей после

имплантации эндопротеза на основе никелида титана в течение 7, 14, 21 и 45 дней, соответственно.

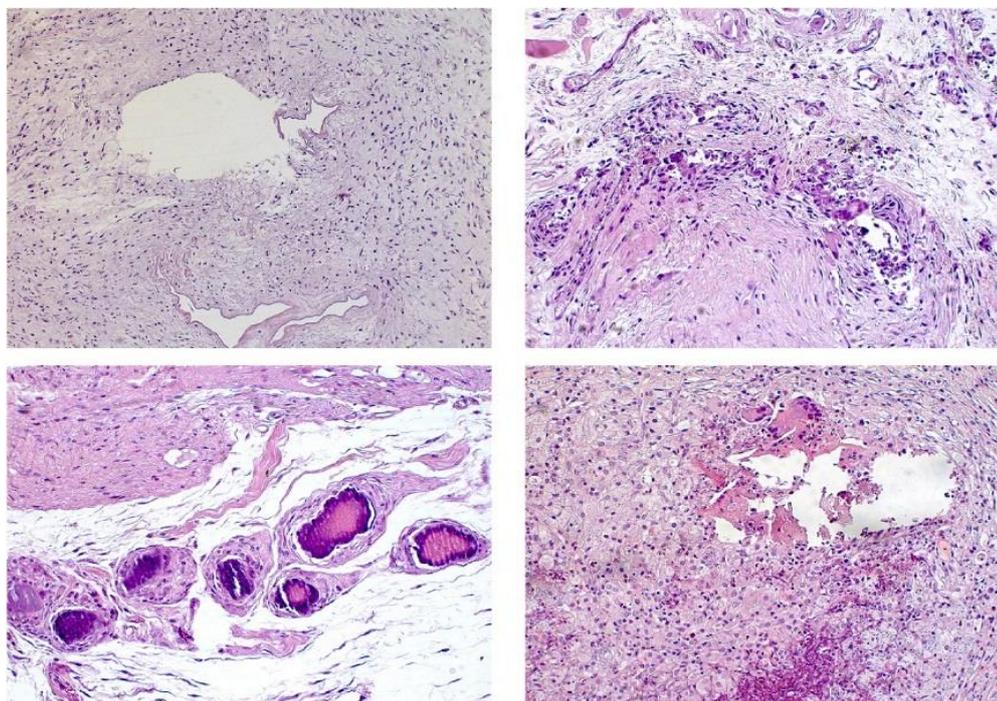


Рисунок 4.6 – Примеры изображений, полученных для гистологического анализа

Видно, что хроматические, а также яркостные и контрастные характеристики изображений, полученных в ходе медицинских экспериментов, весьма различны. Такая нестабильность, характерная для исходных изображений, приводит к необходимости тщательной настройки алгоритмов качественного анализа изображений.

В рамках экспериментального исследования с использованием сканирующего микроскопа для обработки и анализа данных наблюдений в процессе роста и созревания тканей наблюдалось и оценивалось заполнение структуры имплантата клеточными элементами. Данные электронной сканирующей микроскопии представлены монохромными изображениями в различных масштабах (более 100). Полученные изображения в зависимости от анализируемых деталей имеют различное разрешение. Разрешение варьируется от  $500 \times 700$  до  $5120 \times 3840$  пикселей.

Примеры изображений, полученных растровой микроскопией в разные дни медицинских экспериментов, приведены на рисунке 4.7. Также видно, что яркость и контрастность изображения варьируется от изображения к изображению.

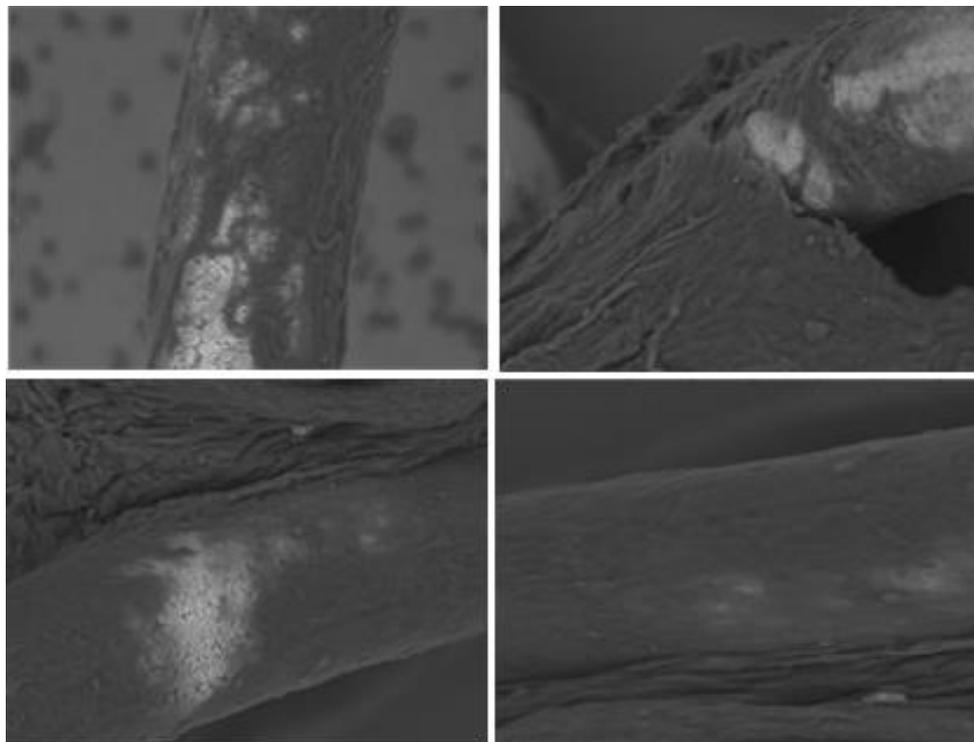


Рисунок 4.7 – Примеры изображений сканирующего электронного микроскопа

Принимая это во внимание, решено оценить предложенный способ с и без этапа предварительной, коррекции яркости на основе модифицированного алгоритма Retinex.

#### 4.4.2. Оценка параметров яркости изображений

Для экспериментального исследования взято 140 изображений за весь период полномасштабного медицинского эксперимента на кроликах. Результаты обработки алгоритмом Retinex для гистологических изображений показаны на рисунке 4.8, а для растровых микроскопических изображений на рисунке 4.9. Как видно на изображениях, обработанных алгоритмом Retinex, уровень яркости стал примерно таким же, локальный контраст также изменился.

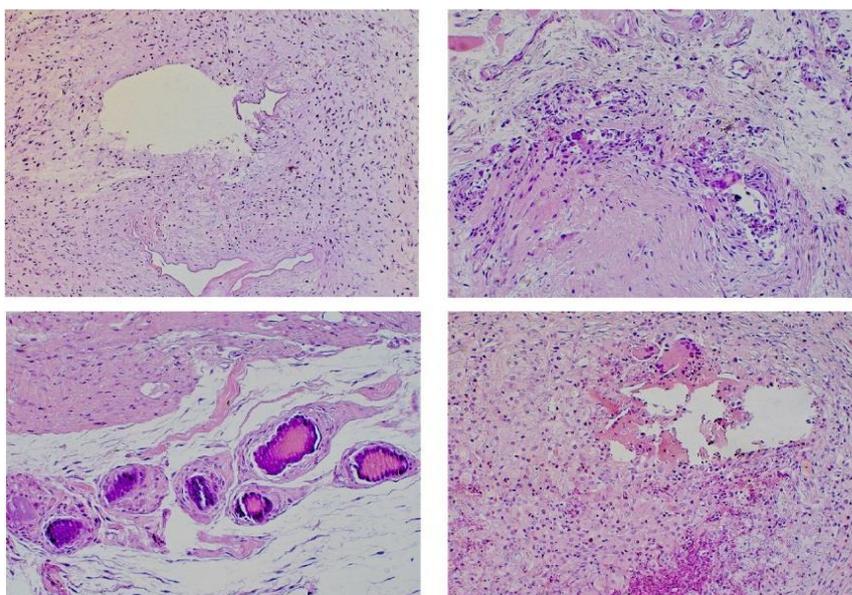


Рисунок 4.8 – Примеры гистологических изображений, обработанных алгоритмом Retinex

Технические данные характеристик яркости, такие как среднее значение и стандартное отклонение (SD) медицинских изображений до и после коррекции яркости с помощью алгоритма Retinex приведены в таблицах 4.1-4.3, где приведены статистические данные характеристик яркости для всего набор изображений, полученных в клинических экспериментах.

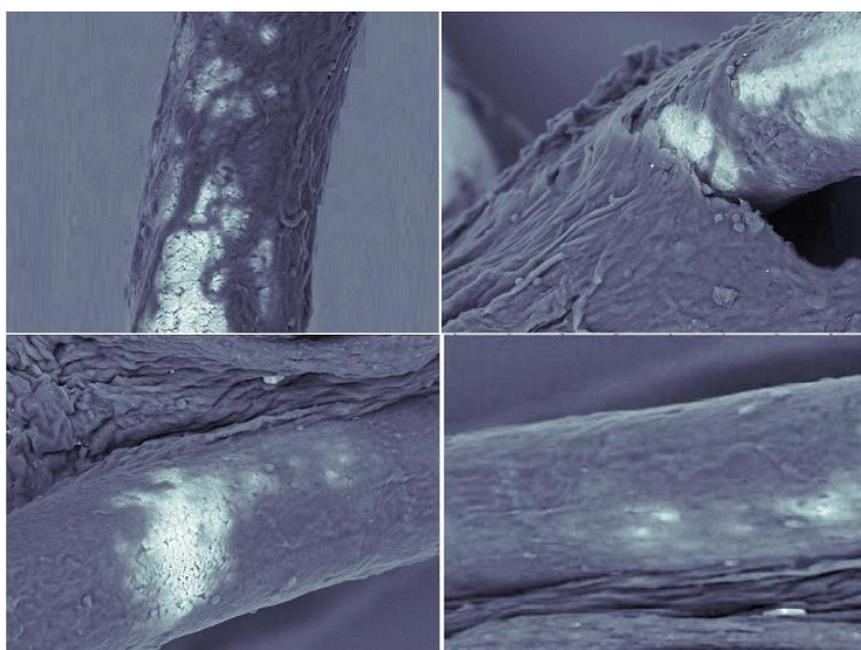


Рисунок 4.9 – Примеры изображений сканирующего электронного микроскопа, обработанных алгоритмом Retinex

В ходе исследований для гистологических изображений средняя целевая яркость установлена равной 190, а для растровых микроскопических изображений – 127. Это позволит дополнительно унифицировать диапазоны значений параметров алгоритмов для обнаружения краев, цветового кодирования и анализа объектов, представляющих интерес.

Таблица 4.1 – Яркость характеристик моделей изображений.

Изображений	До коррекции яркости		После коррекции яркости	
	Mean	SD	Mean	SD
Гистологические изображения				
Из. 1	204.22	15.73	190.03	12.43
Из. 2	227.91	23.71	190.13	11.20
Из. 3	230.95	24.93	189.90	11.02
Из. 4	214.67	27.67	189.95	12.20
Изображения сканирующего электронного микроскопа				
Из. 1	83.26	12.57	127.48	22.14
Из. 2	112.89	21.17	127.02	29.53
Из. 3	63.25	24.71	126.95	37.20
Из. 4	70.10	14.30	127.54	25.42

Таблица 4.2 – Характеристики яркости медицинских изображений.

Временной период	До коррекции яркости		После коррекции яркости	
	Mean	SD	Mean	SD
Гистологические изображения				
7 дней	202.12-215.32	14.23-18.32	189.87-190.33	12.29-12.65
14 дней.	212.27-245.91	22.70-24.12	189.91-190.15	11.12-11.44
21 день	218.39-239.45	24.03-26.09	189.95-190.23	10.92-11.14
45 дней	205.87-224.61	26.97-28.17	189.90-190.17	12.03-12.26
Изображения сканирующего электронного микроскопа				
7 дней	78.36-88.67	11.39-12.68	126.99-127.12	19.81-24.15
14 дней.	69.74-95.82	11.13-34.40	126.17-127.04	21.16-37.15
21 день	60.39-71.25	25.27-28.31	126.92-127.24	25.48-36.93
45 дней	92.37-116.96	23.85-44.96	126.68-127.98	31.72-39.49

Таблица 4.3 – Оценка диапазонов характеристик яркости медицинских изображений.

Временной период	До коррекции яркости		После коррекции яркости	
	Mean	SD	Mean	SD
Гистологические изображения				
7 дней	13.20	4.09	0.46	0.36
14 дней	33.64	1.42	0.24	0.32
21 день	21.06	2.06	0.28	0.22
45 дней	18.74	1.20	0.27	0.23
Изображения сканирующего электронного микроскопа				
7 дней	10.31	1.29	0.13	4.34
14 дней	26.08	23.27	0.87	15.99
21 день	10.86	3.04	0.32	11.45
45 дней	24.59	21.11	1.3	7.77

Как видно из таблицы 4.3, диапазон среднего значения яркости для набора изображений был значительно уменьшен в изображениях, обработанных по алгоритму Retinex, и составляет 0,24-0,46 единиц. Аналогичный результат наблюдается и для изображений, полученных с помощью сканирующего электронного микроскопа.

В случае гистологических изображений диапазон стандартного отклонения после коррекции освещенности уменьшался. Хотя, для изображений, полученных со сканирующего микроскопа, этот диапазон увеличился. Это, в свою очередь, может быть охарактеризовано особенностью изображений (разные углы и параметры наблюдаемых объектов).

#### 4.5.3. Оценка показателей и параметров в эксперименте

Основной вычислительный эксперимент проводился с использованием программного обеспечения Matlab. Используются следующие количественные характеристики: контуры и общая площадь исследуемого имплантата, а также контуры и доля ткани, проросшей на сетке.

На рисунках 4.10 и 4.11 показаны примеры карт с цветовой кодировкой, полученных для гистологических данных и изображений сканирующего

электронного микроскопа. На основании этих карт рассчитывали морфологические показатели и оценивали рост тканей.

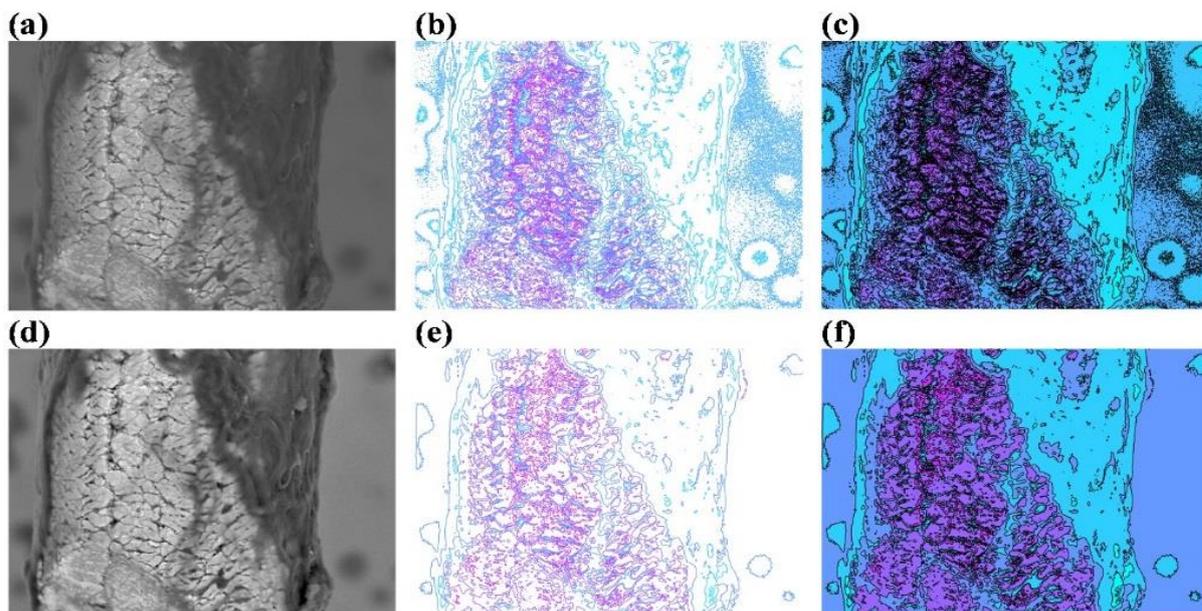


Рисунок 4.10 – Примеры обработки изображений сканирующим электронным микроскопом: (a, d) исходное; (b, e) изображение с коррекцией яркости; (c, f) карта с цветовой кодировкой

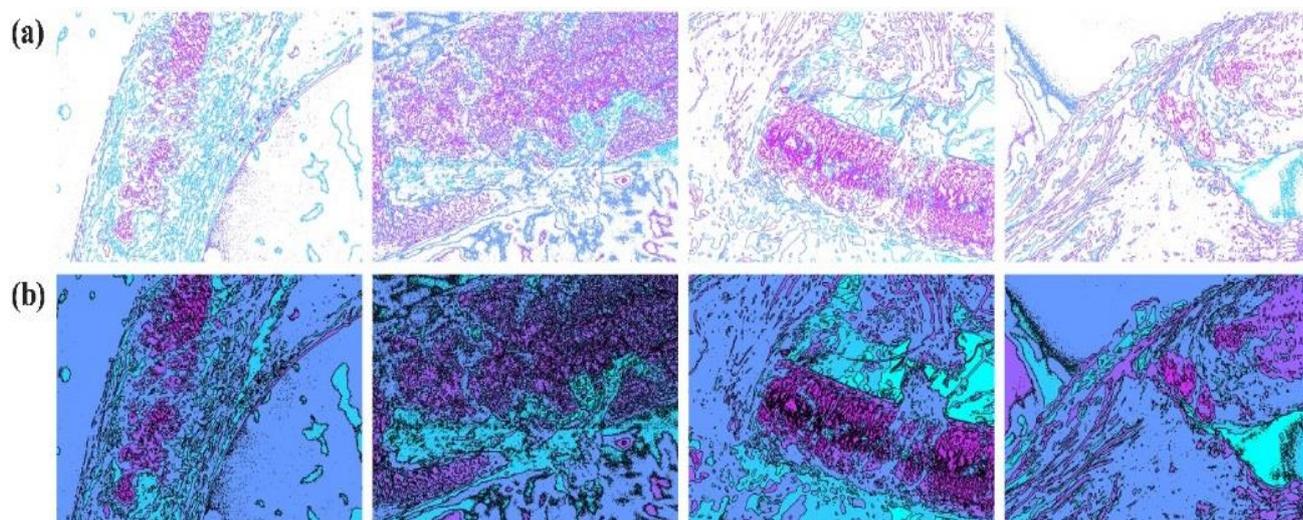


Рисунок 4.11 – Примеры карт с цветовой кодировкой для растровых микроскопических изображений (a, b)

Результаты количественного гистологического анализа, полученные с использованием разработанного Способа, сведены в таблицы 4.4-4.5. Таблицы отражают влияние предварительной обработки на рассчитанные показатели.

В таблице 4.4 представлены оценки данных морфометрических показателей по погрешности расчета по основным исследуемым параметрам. Оценка проводилась для различных вариантов Способа: обычная методика расчета; расчет с цветовым кодированием; расчет с цветовым кодированием и коррекцией яркости.

Оценка прорастания тканей проводилась на основе изображений сканирующей электронной микроскопии. Поэтому для получения более объективных данных использованы изображения, полученные с разных ракурсов (перспективы).

Таблица 4.4 – Оценка погрешности морфометрических параметров в различные периоды времени.

Временной период	Традиционная методика расчета		
	суд	Коллагеновые волокна	Эластичные волокна
7 дней	8.0%	2.8%	10.3%
14 дней	10.5%	2.2%	8.1%
21 день	13.4%	3.6%	14.4%
45 дней	7.3%	1.2%	8.5%
Расчет с цветовой кодировкой			
7 дней	7.1%	2.5%	9.6%
14 дней	9.6%	2.1%	7.6%
21 день	12.7%	3.4%	13.5%
45 дней	7.1%	1.1%	7.9%
Расчет с цветовым кодированием и коррекцией яркости			
7 дней	6.7%	2.3%	9.2%
14 дней	9.2%	2.0%	7.3%
21 день	12.1%	3.2%	12.9%
45 дней	6.8%	1.0%	7.5%

В рамках исследования для оценки Способа медицинский эксперт определил объекты, которые были определены как ткани, волокна, эритроциты и т.д., а области со структурой имплантата определены отдельно. Для указанных эталонных образцов параметры рассчитаны с учетом показателей текстурных характеристик и цветового кода.

Учитывая это, площадь доли проросшей ткани была рассчитана. Он определяется как отношение площади проросшей ткани к площади соответствующей части сетки имплантата. Сравнение показателей прорастания тканей, полученных медицинским экспертом на основе классического оценочного подхода, проводилось с помощью предложенного Способа в двух режимах – с коррекцией яркости и без этой коррекции.

В таблице 4.5 представлены данные о прорастании тканей, полученные при измерении изучаемых геометрических показателей текстуры для ключевых временных этапов медицинского эксперимента (7, 14, 21 и 45 дней). Согласно данным таблицы 4.5 можно наблюдать зависимость площади проросшей ткани на соответствующих снимках от времени.

Таблица 4.5 – Оценка площади роста тканей, в %.

Период времени	Перспектива 1	Перспектива 2	Перспектива 3
Обычная методика расчета			
7 дней	24.4	24.7	24.9
14 дней	47.9	48.1	48.3
21 день	59.4	59.6	59.8
45 дней	68.3	68.5	68.7
Расчет с цветовым кодированием			
7 дней	27.1	27.4	27.6
14 дней	53.1	53.3	53.5
21 день	66.0	66.2	66.4
45 дней	76.0	76.1	76.3
Расчет с цветовым кодированием и коррекцией яркости			
7 дней	28.1	28.3	28.5
14 дней	55.1	55.3	55.4
21 день	68.3	68.5	68.7
45 дней	78.6	78.8	78.9

На рисунке 4.12 показаны примеры сегментированных карт (объект интереса), полученных для изображений от сканирующего микроскопа.

Хотя, как видно на цветных картах, области роста с использованием сегментации для изображений, полученных от сканирующего микроскопа за

другой период времени, этот диапазон увеличился. Это, в свою очередь, может быть охарактеризовано особенностью снимков (различные углы и параметры наблюдаемых объектов). На основании этих карт были рассчитаны морфологические показатели и проведена оценка регенерации тканей.

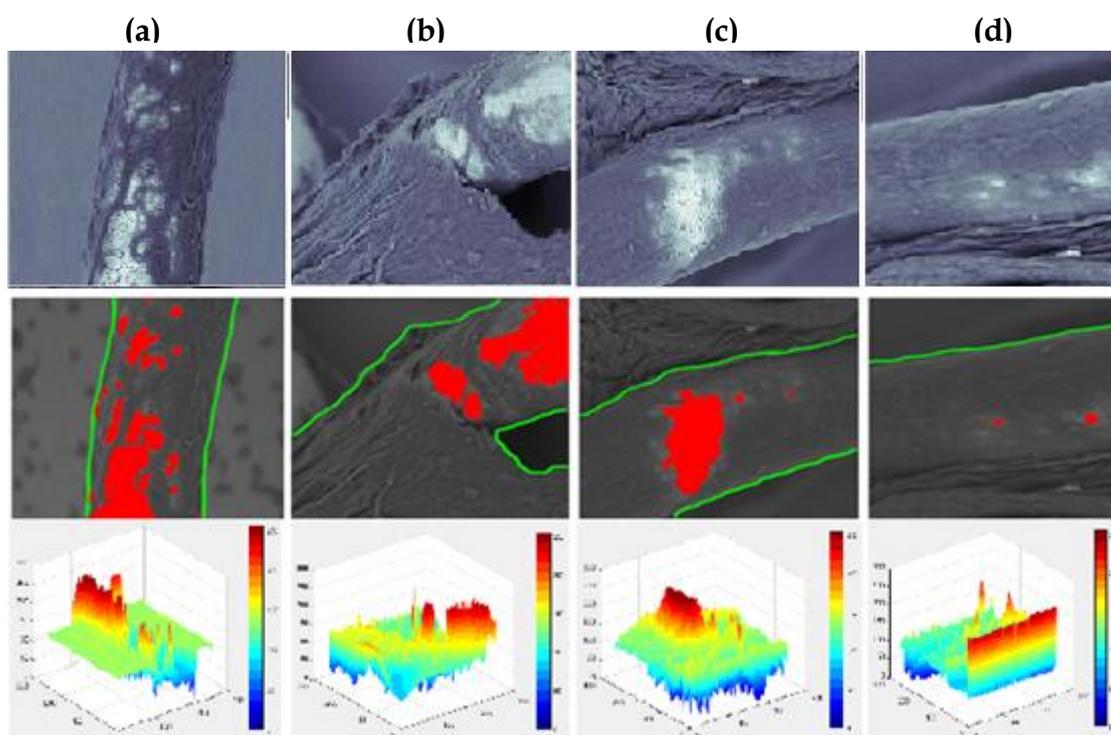


Рисунок 4.12 – Примеры цветных карт для растровых микроскопических изображений нерастительного покрова: а) период времени 7 дней; б) период времени 14 дней; в) период времени 21 день; г) период времени 45 дней

В целом, одинаковые значения площади прорастания тканей получены для разных углов зрения. Предварительная коррекция яркости позволяет более четко отделить ткани и имплантаты. Кроме того, оценка способа по гистологическим данным показала, что коррекция яркости повышает точность искомых оценок.

Результаты количественного гистологического анализа, полученные с использованием разработанного Способа, приведены в таблице 4.6. В таблице отражено влияние предварительной обработки на расчетные показатели.

В качестве оценки используются данные о состоянии тканей на 7, 14, 21 и 45 сутки (14 день – начало активного процесса регенерации), которые получены на основе традиционных гистологических подходов без использования

компьютерных средств. Одновременно оценивалась работа предложенного способа с и без внедрением световой коррекции.

Таблица 4.6 – Измерение скорости роста и морфометрических параметров в различные периоды времени

<b>Временной период</b>	<b>Площадь объекта в пикселях</b>	<b>Растущая область в пикселях</b>	<b>Нерастущая область в пикселях</b>	<b>Скорость роста %</b>	<b>Не раст. область %</b>
Без коррекции яркости					
<b>7 дней</b>	28277	19057	9220	67%	33%
<b>14 дней</b>	40860	34364	6496	84%	16%
<b>21 день</b>	43322	38648	4674	89%	11%
<b>45 дней</b>	51573	51397	176	98%	2%
С коррекцией яркости					
<b>7 дней</b>	29253	20125	9128	69%	31%
<b>14 дней</b>	42875	36667	6208	86%	14%
<b>21 день</b>	44396	39946	4450	90%	10%
<b>45 дней</b>	53585	53328	257	99%	1%

Оценка прорастания тканей производилась на основе изображений, полученных с помощью сканирующей электронной микроскопии. Поэтому для более объективных данных использовались изображения, полученные под разными углами. В рамках исследования для оценки компьютерных методик медицинским специалистом указывались объекты, которые определялись как ткань, зона роста, не зона роста и т.д., а также отдельно указывались участки со структурой имплантата. Для указанных эталонных образцов рассчитывались параметры с учетом этих показателей.

На рисунках 4.13 представлены сравнительные графики средних значений скорости роста для тестовых изображений за соответствующий период времени наблюдений.

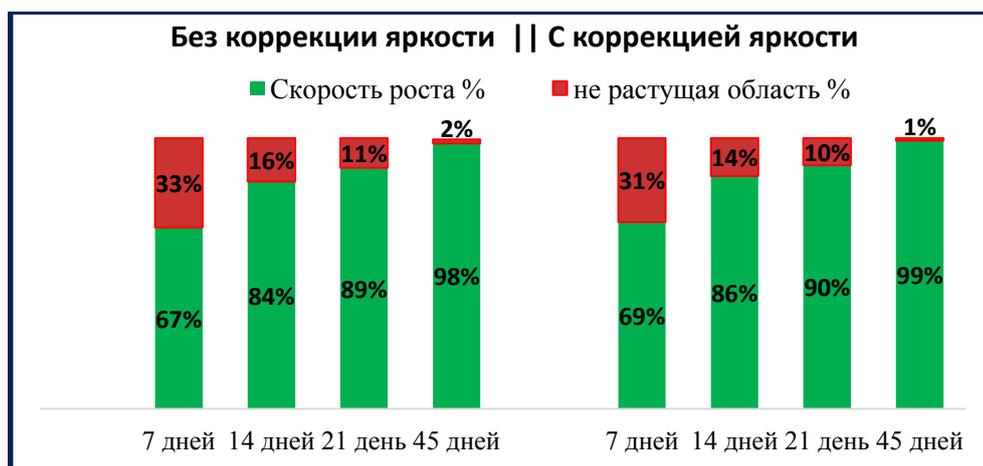


Рисунок 4.13 – Графические результаты скорости роста клеток в различные периоды времени

Предложенный Способ позволяет получить карту краев интересующего объекта с большей точностью, в среднем на 3-7%. Кроме того, Способ демонстрирует меньший процент пикселей, ошибочно обнаруженных как края для не растущей области.

#### 4.5. Выводы по четвертой главе

Получены следующие результаты.

1. Предварительная обработка изображений с учетом коррекции яркости повышает точность оценок, что важно для описания особенностей процесса. Коррекция яркости на основе алгоритма Retinex также позволяет указать новую оценку и значительно снизить разброс значений (погрешность) с 8-12%.

2. Данные, представленные в таблицах 4.5, показывают, что новый способ обработки данных позволяет проводить более точную оценку данных при анализе изучаемых процессов. В то же время это позволяет упростить работу эксперта-гистолога за счет использования более универсального алгоритма обработки (шиарлет-преобразование с контрастированием цветовым кодированием), который не требует использования трудоемких традиционных процедур гистологического анализа.

3. Анализ результатов обработки данных сканирующего электронного микроскопа показывает эффективность разработанного способа для оценки

основных показателей количественной гистологии. Это значительно увеличивает скорость обработки данных и получения обновленных оценок.

4. Использование механизма коррекции яркости, основанного на технологии Retinex, позволяет медицинским специалистам более четко видеть детали изучаемых объектов на изображениях. При оценке прорастания тканей это выражается в более четком определении областей, в среднем на 1-3%. Это важно с точки зрения оценки медицинских показателей. Разработанные алгоритмические инструменты предлагаемого способа полезны для опытных гистологов при обработке больших объемов визуальных данных.

5. Разработанный способ показал свою эффективность по скорости (на два порядка) и точности (в среднем на 3-7%), обеспечив возможность качественной предварительной обработки для повышения контрастности и яркости, а также фильтрации шумов. Предложенные вычислительные процедуры обеспечили эффективное выполнение алгоритма сегментации и преобразования сдвига с использованием модифицированного алгоритма FFST. Применение разработанного способа позволяет повысить точность выбора линейных структур и визуальное качество изображений исследуемых клинических объектов.

6. В исследовании предложены элементы алгоритмизации и автоматизации для анализа гистологических образцов. Это позволяет значительно ускорить процедуры диагностического скрининга для специализированного анализа изображений. В дальнейшем, автор намерен развивать алгоритмическое обеспечение, связанное с процессом сегментации и фильтрации медицинских изображений для усовершенствования новой гибридной методики, в части ее распараллеливания и автоматизации в рамках экспертно-аналитической системы.

## ЗАКЛЮЧЕНИЕ

Основным научным результатом диссертации является разработка и исследование методов и алгоритмов, основанных на компьютерном зрении, предназначенных для обнаружения контуров и сегментации, представляющих интерес объектов (патологии, опухоли). Полученные результаты имеют как теоретическое, так и прикладное значение.

1. Разработан метод сегментации по группам объектов, который характеризуется созданием нового порога для сегментации объектов с использованием комбинации порогового значения Оцу и нечеткой кластеризации, что позволяет значительно увеличить скорость и улучшить точность сегментации и классификации объектов на 2-3% по сравнению с современными методами медицинской сегментации (2016-2019 гг.).
2. Предложен алгоритм классификации объектов интереса – опухолей (доброкачественных или злокачественных) с использованием разработанного метода сегментации, извлеченных признаков и алгоритма на основе нейронной сети. Набор из 18 информационных функций извлечены с использованием GLCM, что позволило повысить точность классификации объектов (опухоль молочной железы) на 4-5%. Также 13 информационные функции извлечены с использованием DWT, что позволило повысить точность классификации объекта (опухоль головного мозга) на 3-4%. С помощью функции извлечения разработанный алгоритм позволяет повысить точность диагностики на МРТ и КТ изображениях: опухолей головного мозга (в течение 120 сек. с точностью 99%); опухолей молочной железы (в течение 200 сек. с точностью 98%).
3. Разработан метод определения параметров (порогового значения), которые важны для автоматической сегментации с использованием дискретного вейвлет-преобразования, что позволяет повысить точность сегментации и обнаружения границ объектов интереса (легких) на 1-2% по сравнению с современными методами определения границ легких на медицинских снимках CXR (2014-2019 гг.).

4. Разработаны вычислительная методика и алгоритмическое обеспечение обработки и анализа изображений СХР и КТ на основе усовершенствованного алгоритма CPNN и модифицированного алгоритма шиарлет-преобразования (FFST) для определения границ легких и распознавания патологий на рентгенограммах грудной клетки, включая обнаружение опухолей на изображениях КТ, которые позволяют повысить точность диагностики. Средняя точность распознавания объектов (патологий) на исследуемых базах данных достигает 96 %.
5. Предложен способ геометрического анализа и визуализации объектов интереса на основе модификации алгоритмического обеспечения шиарлет-преобразования и контрастирования изображений цветовым кодированием. Выполнены численные исследования экспериментальных данных сканирующей электронной микроскопии для оценки показателей регенерации тканей (размеры зоны прорастания и скорости роста) на имплантатах различного типа в рамках комплексного медицинского эксперимента. Результаты экспериментов показали быстроедействие и высокую точность разработанного способа (на 3-7 %) относительно классического подхода в гистологии.

**СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ**

1. Abdel-Maksoud E., Elmogy M., Al-Awadi R. Brain tumor segmentation based on a hybrid clustering technique // Egyptian Informatics Journal. – 2015. – Т. 16. – №. 1. – С. 71-81.
2. Abdi H., Williams L. J. Principal component analysis //Wiley interdisciplinary reviews: computational statistics. – 2010. – Т. 2. – №. 4. – С. 433-459.
3. Ahmad W. S. H. M. W. et al. Classification of infection and fluid regions in chest x-ray images //2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA). – IEEE, 2016. – С. 1-5.
4. Ain Q., Jaffar M. A., Choi T. S. Fuzzy anisotropic diffusion based segmentation and texture based ensemble classification of brain tumor //applied soft computing. – 2014. – Т. 21. – С. 330-340.
5. Al-Dmour H., Al-Ani A. A steganography embedding method based on edge identification and XOR coding //Expert systems with Applications. – 2016. – Т. 46. – С. 293-306.
6. 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.
7. Alias A., Paulchamy B. Detection of Breast Cancer Using Artificial Neural Networks //International Journal of Innovative Research in Science, Engineering and Technology. – 2014. – Т. 3. – №. 3. – С. 10053-10060.
8. Alipoor M., Imandoost S., Haddadnia J. Designing edge detection filters using particle swarm optimization //2010 18th Iranian Conference on Electrical Engineering. – IEEE, 2010. – С. 548-552.
9. Andrabi Y. et al. Advances in CT imaging for urolithiasis //Indian journal of urology: IJU: journal of the Urological Society of India. – 2015. – Т. 31. – №. 3. – С. 185.
10. Arganda-Carreras I. et al. 3D reconstruction of histological sections: Application to mammary gland tissue //Microscopy research and technique. – 2010. – Т. 73. – №. 11. – С. 1019-1029.
11. Azad P., Gockel T., Dillmann R. Computer Vision: principles and practice. – 2008.
12. Baboo S. S., Iyyapparaj E. A classification and analysis of pulmonary nodules in CT images using random forest //2018 2nd International Conference on Inventive Systems and Control (ICISC). – IEEE, 2018. – С. 1226-1232.
13. Badawy S. M. et al. Breast cancer detection with mammogram segmentation: a qualitative study //International Journal of Advanced Computer Science and

- Application. – 2017. – T. 8. – №. 10.
14. Bahadure N. B., Ray A. K., Thethi H. P. Comparative approach of MRI-based brain tumor segmentation and classification using genetic algorithm //Journal of digital imaging. – 2018. – T. 31. – №. 4. – C. 477-489.
  15. Bahadure N. B., Ray A. K., Thethi H. P. Image analysis for MRI based brain tumor detection and feature extraction using biologically inspired BWT and SVM //International journal of biomedical imaging. – 2017. – T. 2017.
  16. Beale M. H., Hagan M. T., Demuth H. B. Neural network toolbox™ user's guide //R2012a, The MathWorks, Inc., 3 Apple Hill Drive Natick, MA 01760-2098,, www.mathworks.com. – 2012.
  17. Benco M. et al. An advanced approach to extraction of colour texture features based on GLCM //International Journal of Advanced Robotic Systems. – 2014. – T. 11. – №. 7. – C. 104.
  18. Bhide A. S., Patil P., Dhande S. Brain Segmentation using Fuzzy C means clustering to detect tumour Region //International Journal of Advanced Research in Computer Science and Electronics Engineering. – 2012. – T. 1. – №. 2. – C. 85-90.
  19. Borovec J. et al. Registration of multiple stained histological sections //2013 IEEE 10th International Symposium on Biomedical Imaging. – IEEE, 2013. – C. 1034-1037.
  20. BrainWeb B. Simulated brain database //Online: <http://brainweb.bic.mni.mcgill.ca/cgi/brainweb2>. – 2010.
  21. Cadena L. et al. Brain's tumor image processing using shearlet transform //Applications of Digital Image Processing XL. – International Society for Optics and Photonics, 2017. – T. 10396. – C. 103961B.
  22. Cadena L. et al. Processing medical images by new several mathematics shearlet transform. – 2016.
  23. Cadena L., Zotin A., Cadena F. Enhancement of medical image using spatial optimized filters and OpenMP technology //Proceedings of the International MultiConference of Engineers and Computer Scientists. – 2018. – T. 1.
  24. Candemir S. et al. Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration //IEEE transactions on medical imaging. – 2013. – T. 33. – №. 2. – C. 577-590.
  25. Candemir S., Antani S. A review on lung boundary detection in chest X-rays //International journal of computer assisted radiology and surgery. – 2019. – T. 14. – №. 4. – C. 563-576.
  26. Canny J. A computational approach to edge detection //IEEE Transactions on pattern analysis and machine intelligence. – 1986. – №. 6. – C. 679-698.
  27. Carrington S. J., Bailey A. J. Are there theory of mind regions in the brain? A

- review of the neuroimaging literature //Human brain mapping. – 2009. – T. 30. – №. 8. – C. 2313-2335.
28. Chakravarty M. M. et al. The creation of a brain atlas for image guided neurosurgery using serial histological data //Neuroimage. – 2006. – T. 30. – №. 2. – C. 359-376.
  29. Chauhan A., Mittal N., Khatri S. K. Reduction of Noise of Cloud Medical Images Using Image Enhancement Technique //Advances in Interdisciplinary Engineering. – Springer, Singapore, 2019. – C. 825-835.
  30. Cheng H. D. et al. Approaches for automated detection and classification of masses in mammograms //Pattern recognition. – 2006. – T. 39. – №. 4. – C. 646-668.
  31. Cheng H. D. et al. Automated breast cancer detection and classification using ultrasound images: A survey //Pattern recognition. – 2010. – T. 43. – №. 1. – C. 299-317.
  32. Cheng H. D. et al. Computer-aided detection and classification of microcalcifications in mammograms: a survey //Pattern recognition. – 2003. – T. 36. – №. 12. – C. 2967-2991.
  33. Chiu J. S. et al. Artificial neural network to predict skeletal metastasis in patients with prostate cancer //Journal of medical systems. – 2009. – T. 33. – №. 2. – C. 91.
  34. Christaline J. A., Ramesh R., Vaishali D. Steganalysis with classifier combinations //ARPN Journal of Engineering and Applied Sciences. – 2014. – T. 9. – C. 12.
  35. Conze J. et al. Pitfalls in retromuscular mesh repair for incisional hernia: the importance of the “fatty triangle” //Hernia. – 2004. – T. 8. – №. 3. – C. 255-259.
  36. Coppini G. et al. A computer-aided diagnosis approach for emphysema recognition in chest radiography //Medical engineering & physics. – 2013. – T. 35. – №. 1. – C. 63-73.
  37. Coppini G. et al. Neural networks for computer-aided diagnosis: detection of lung nodules in chest radiograms //IEEE Transactions on Information Technology in Biomedicine. – 2003. – T. 7. – №. 4. – C. 344-357.
  38. Dalmış M. U. et al. Using deep learning to segment breast and fibroglandular tissue in MRI volumes //Medical physics. – 2017. – T. 44. – №. 2. – C. 533-546.
  39. Dalmiya S., Dasgupta A., Datta S. K. Application of wavelet based k-means algorithm in mammogram segmentation //International Journal of Computer Applications. – 2012. – T. 52. – №. 15.
  40. Demirhan A., Törü M., Güler İ. Segmentation of tumor and edema along with healthy tissues of brain using wavelets and neural networks //IEEE journal of biomedical and health informatics. – 2014. – T. 19. – №. 4. – C. 1451-1458.

41. Döhler F. et al. A cellular neural network based method for classification of magnetic resonance images: towards an automated detection of hippocampal sclerosis //Journal of neuroscience methods. – 2008. – T. 170. – №. 2. – C. 324-331.
42. Dou W. et al. A framework of fuzzy information fusion for the segmentation of brain tumor tissues on MR images //Image and vision Computing. – 2007. – T. 25. – №. 2. – C. 164-171.
43. El Adoui M. et al. MRI Breast Tumor Segmentation Using Different Encoder and Decoder CNN Architectures //Computers. – 2019. – T. 8. – №. 3. – C. 52.
44. Fan H., Pei J., Zhao Y. An optimized probabilistic neural network with unit hyperspherical crown mapping and adaptive kernel coverage //Neurocomputing. – 2020. – T. 373. – C. 24-34.
45. Ge J. et al. Computer aided detection of clusters of microcalcifications on full field digital mammograms //Medical Physics. – 2006. – T. 33. – №. 8. – C. 2975-2988.
46. Ghanbari S. et al. New steganalysis method using GLCM and neural network. – 2012.
47. Glaser J., Greene G., Hendricks S. Stereology for biological research: with a focus on neuroscience. – mbf Press, 2007.
48. Guo D. et al. A computer-aided diagnostic system to discriminate SPIO-enhanced magnetic resonance hepatocellular carcinoma by a neural network classifier //Computerized Medical Imaging and Graphics. – 2009. – T. 33. – №. 8. – C. 588-592.
49. Guo L. J. Balance contrast enhancement technique and its application in image colour composition //Remote Sensing. – 1991. – T. 12. – №. 10. – C. 2133-2151.
50. Hamad Y. A., Simonov K. V., Naeem M. B. Detection of Brain Tumor in MRI Images, Using a Combination of Fuzzy C-Means and Thresholding //International Journal of Advanced Pervasive and Ubiquitous Computing (IJAPUC). – 2019. – T. 11. – №. 1. – C. 45-60.
51. Hamad Y. A., Simonov K., Naeem M. B. Brain's tumor edge detection on low contrast medical images //2018 1st Annual International Conference on Information and Sciences (AiCIS). – IEEE, 2018. – C. 45-50.
52. Hamad Y. A., Simonov K., Naeem M. B. Lung Boundary Detection and Classification in Chest X-Rays Images Based on Neural Network //International Conference on Applied Computing to Support Industry: Innovation and Technology. – Springer, Cham, 2019. – C. 3-16.
53. Hamad Y., Mohammed O. K. J., Simonov K. Evaluating of Tissue Germination and Growth Rate of ROI on Implants of Electron Scanning Microscopy Images //Proceedings of the 9th International Conference on Information Systems and

- Technologies. – 2019. – C. 1-7.
54. Hamad Y., Simonov K., Naeem M. B. Breast Cancer Detection and Classification Using Artificial Neural Networks //2018 1st Annual International Conference on Information and Sciences (AiCIS). – IEEE, 2018. – C. 51-57.
  55. Hara H. et al. Surgical planning of Isshiki type I thyroplasty using an open-source Digital Imaging and Communication in Medicine viewer OsiriX //Acta otolaryngologica. – 2014. – T. 134. – №. 6. – C. 620-625.
  56. Harshavardhan M., Rao S. V. GLCM architecture of image extraction //International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE). – 2014. – T. 3. – №. 1. – C. 75-82.
  57. Hasan S. M. A., Ko K. Depth edge detection by image-based smoothing and morphological operations //Journal of Computational Design and Engineering. – 2016. – T. 3. – №. 3. – C. 191-197.
  58. Häuser S., Steidl G. Fast finite shearlet transform //arXiv preprint arXiv:1202.1773. – 2012.
  59. Heath M. et al. Current status of the digital database for screening mammography //Digital mammography. – Springer, Dordrecht, 1998. – C. 457-460.
  60. Hien N. M., Binh N. T., Viet N. Q. Edge detection based on Fuzzy C Means in medical image processing system //2017 International Conference on System Science and Engineering (ICSSE). – IEEE, 2017. – C. 12-15.
  61. Ho T. K. K. et al. Utilizing Pretrained Deep Learning Models for Automated Pulmonary Tuberculosis Detection Using Chest Radiography //Asian Conference on Intelligent Information and Database Systems. – Springer, Cham, 2019. – C. 395-403.
  62. Hogeweg L. et al. Automatic detection of tuberculosis in chest radiographs using a combination of textural, focal, and shape abnormality analysis //IEEE transactions on medical imaging. – 2015. – T. 34. – №. 12. – C. 2429-2442.
  63. Irianov Y. M., Kiryanov N. A. Bone Tissue Repair During Implantation of Titanium Nickelide Mesh: Scanning Electron Microscopy and X-ray Electron Probe Microanalysis Observation //Journal of Tissue Repair and Regeneration. – 2018. – T. 1. – №. 1. – C. 28.
  64. Jaeger S. et al. Automatic tuberculosis screening using chest radiographs //IEEE transactions on medical imaging. – 2013. – T. 33. – №. 2. – C. 233-245.
  65. Jaeger S. et al. Two public chest X-ray datasets for computer-aided screening of pulmonary diseases //Quantitative imaging in medicine and surgery. – 2014. – T. 4. – №. 6. – C. 475.
  66. Jansen J. et al. Orbital volume analysis: validation of a semi-automatic software segmentation method //International journal of computer assisted radiology and surgery. – 2016. – T. 11. – №. 1. – C. 11-18.

67. Jeong H., Kim C. I. Adaptive determination of filter scales for edge detection //IEEE Transactions on Pattern Analysis & Machine Intelligence. – 1992. – №. 5. – C. 579-585.
68. Jiang J., Trundle P., Ren J. Medical image analysis with artificial neural networks //Computerized Medical Imaging and Graphics. – 2010. – T. 34. – №. 8. – C. 617-631.
69. Juneja M., Sandhu P. S. Design and development of an improved adaptive median filtering method for impulse noise detection //International journal of computer and electrical engineering. – 2009. – T. 1. – №. 5. – C. 627.
70. Kamil M. Y., Salih A. M. Mammography Images Segmentation via Fuzzy C-mean and K-mean //International Journal of Intelligent Engineering and Systems. – 2019. – T. 12. – №. 1. – C. 22-29.
71. Kang X. et al. Diffusion properties of cortical and pericortical tissue: regional variations, reliability and methodological issues //Magnetic Resonance Imaging. – 2012. – T. 30. – №. 8. – C. 1111-1122.
72. Kanojia M. G., Abraham S. Breast cancer detection using RBF neural network //2016 2nd International Conference on Contemporary Computing and Informatics (IC3I). – IEEE, 2016. – C. 363-368.
73. Keserci B., Yoshida H. Computerized detection of pulmonary nodules in chest radiographs based on morphological features and wavelet snake model //Medical Image Analysis. – 2002. – T. 6. – №. 4. – C. 431-447.
74. Khmelevskaya I., Rykлина E., Korotitskiy A. Application of thermomechanically treated Ti-Ni SMA //Materials Science Foundations. – Trans Tech Publications Ltd, 2015. – T. 81. – C. 603-637.
75. Kieu P. N. et al. Applying multi-CNNs model for detecting abnormal problem on chest x-ray images //2018 10th International Conference on Knowledge and Systems Engineering (KSE). – IEEE, 2018. – C. 300-305.
76. Kim J., Horwitz B. Investigating the neural basis for fMRI-based functional connectivity in a blocked design: application to interregional correlations and psycho-physiological interactions //Magnetic resonance imaging. – 2008. – T. 26. – №. 5. – C. 583-593.
77. Kishor N. et al. Facial expression identification by using principle component analysis //Int. J. Adv. Eng. Glob. Technol. – 2015. – T. 3. – №. 5. – C. 579-585.
78. Kobashi S. et al. Volume-quantization-based neural network approach to 3D MR angiography image segmentation //Image and Vision Computing. – 2001. – T. 19. – №. 4. – C. 185-193.
79. Kong N. S. P. et al. Enhancement of microscopic images using modified self-adaptive plateau histogram equalization //2009 International Conference on Computer Technology and Development. – IEEE, 2009. – T. 2. – C. 308-310.

80. Koprivanac M. et al. Degenerative mitral valve disease-contemporary surgical approaches and repair techniques //Annals of cardiothoracic surgery. – 2017. – T. 6. – №. 1. – C. 38.
81. Kutyniok G., Labate D. (ed.). Shearlets: Multiscale analysis for multivariate data. – Springer Science & Business Media, 2012.
82. Labate D. et al. Sparse multidimensional representation using shearlets //Wavelets XI. – International Society for Optics and Photonics, 2005. – T. 5914. – C. 59140U.
83. Lal S. et al. Efficient algorithm for contrast enhancement of natural images //Int. Arab J. Inf. Technol. – 2014. – T. 11. – №. 1. – C. 95-102.
84. Lauterbur P. C. Image formation by induced local interactions: examples employing nuclear magnetic resonance //nature. – 1973. – T. 242. – №. 5394. – C. 190-191.
85. Leite M. et al. 3D texture-based classification applied on brain white matter lesions on MR images //Medical Imaging 2016: Computer-Aided Diagnosis. – International Society for Optics and Photonics, 2016. – T. 9785. – C. 97852N.
86. Lewandowska-Szumieł M., Komender J. Interaction between tissues and implantable materials //Frontiers of medical and biological engineering: the international journal of the Japan Society of Medical Electronics and Biological Engineering. – 2000. – T. 10. – №. 2. – C. 79-82.
87. Li G. et al. Crowdsourced data management: A survey //IEEE Transactions on Knowledge and Data Engineering. – 2016. – T. 28. – №. 9. – C. 2296-2319.
88. Li X., Chen L., Chen J. A visual saliency-based method for automatic lung regions extraction in chest radiographs //2017 14th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP). – IEEE, 2017. – C. 162-165.
89. Li Y. et al. Fast and efficient molecule detection in localization-based super-resolution microscopy by parallel adaptive histogram equalization //ACS nano. – 2013. – T. 7. – №. 6. – C. 5207-5214.
90. Lim W. Q. The discrete shearlet transform: A new directional transform and compactly supported shearlet frames //IEEE Transactions on image processing. – 2010. – T. 19. – №. 5. – C. 1166-1180.
91. Lin J. S. Segmentation of medical images through a penalized fuzzy Hopfield network with moments preservation //Journal of The Chinese Institute of Engineers. – 2000. – T. 23. – №. 5. – C. 633-643.
92. Lisboa P. J., Taktak A. F. G. The use of artificial neural networks in decision support in cancer: a systematic review //Neural networks. – 2006. – T. 19. – №. 4. – C. 408-415.
93. Liu J. et al. A survey of MRI-based brain tumor segmentation methods //Tsinghua

- Science and Technology. – 2014. – T. 19. – №. 6. – C. 578-595.
94. Liu L. et al. Automated breast tumor detection and segmentation with a novel computational framework of whole ultrasound images //Medical & biological engineering & computing. – 2018. – T. 56. – №. 2. – C. 183-199.
  95. Lo S. C. B. et al. Artificial convolution neural network for medical image pattern recognition //Neural networks. – 1995. – T. 8. – №. 7-8. – C. 1201-1214.
  96. Lukac R., Plataniotis K. N. (ed.). Color image processing: methods and applications. – CRC press, 2018.
  97. Mandal R., Gupta M., Kar C. Automated ROI detection for histological image using fuzzy c-means and K-means algorithm //2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT). – IEEE, 2016. – C. 1173-1178.
  98. Mathews A. B., Jeyakumar M. K. Performance Analysis of Machine Learning Based Classifiers for the Diagnosis of Lung Cancer & Comparison //Indian Journal of Public Health Research & Development. – 2018. – T. 9. – №. 12. – C. 2672-2678.
  99. Meghdadi N. et al. Personalized image-based tumor growth prediction in a convection–diffusion–reaction model //Acta Neurologica Belgica. – 2018. – C. 1-9.
  100. Milletari F., Navab N., Ahmadi S. A. V-net: Fully convolutional neural networks for volumetric medical image segmentation //2016 Fourth International Conference on 3D Vision (3DV). – IEEE, 2016. – C. 565-571.
  101. Mohanty F. et al. Digital mammogram classification using 2D-BDWT and GLCM features with FOA-based feature selection approach //Neural Computing and Applications. – 2019. – C. 1-15.
  102. Mörchen F. Time series feature extraction for data mining using DWT and DFT. – 2003.
  103. Nagel R. H. et al. Analysis of methods for reducing false positives in the automated detection of clustered microcalcifications in mammograms //Medical Physics. – 1998. – T. 25. – №. 8. – C. 1502-1506.
  104. Nandhagopal N., Gandhi K. R., Sivasubramanian R. Probabilistic neural network based brain tumor detection and classification system //Research Journal of Applied Sciences, Engineering and Technology. – 2015. – T. 10. – №. 12. – C. 1347-1357.
  105. Nanthagopal A. P., Sukanesh R. Wavelet statistical texture features-based segmentation and classification of brain computed tomography images //IET image processing. – 2013. – T. 7. – №. 1. – C. 25-32.
  106. Nixon M., Aguado A. Feature extraction and image processing for computer vision. – Academic Press, 2019.

107. Papadopoulos A., Fotiadis D. I., Likas A. An automatic microcalcification detection system based on a hybrid neural network classifier //Artificial intelligence in Medicine. – 2002. – T. 25. – №. 2. – C. 149-167.
108. Patil R. C., Bhalchandra A. S. Brain tumour extraction from MRI images using MATLAB //International Journal of Electronics, Communication & Soft Computing Science and Engineering. – 2012. – T. 2. – №. 1. – C. 1-4.
109. Priya E., Srinivasan S. Automated object and image level classification of TB images using support vector neural network classifier //Biocybernetics and Biomedical Engineering. – 2016. – T. 36. – №. 4. – C. 670-678.
110. Qian W. et al. Computerized analysis of cellular features and biomarkers for cytologic diagnosis of early lung cancer //Analytical and Quantitative Cytology and Histology. – 2007. – T. 29. – №. 2. – C. 103-111.
111. Qu Z., Zhang L. Research on image segmentation based on the improved Otsu algorithm //2010 Second International Conference on Intelligent Human-Machine Systems and Cybernetics. – IEEE, 2010. – T. 2. – C. 228-231.
112. Rutkov I. M., Robbins A. W. Hernioplasty with mesh implantanti //Surg. Clin. North Am. – 1993. – T. 73. – C. 413-426.
113. Saad M. N. et al. Image segmentation for lung region in chest X-ray images using edge detection and morphology //2014 IEEE International Conference on Control System, Computing and Engineering (ICCSCE 2014). – IEEE, 2014. – C. 46-51.
114. Saba T. et al. Lung nodule detection based on ensemble of hand crafted and deep features //Journal of medical systems. – 2019. – T. 43. – №. 12. – C. 332.
115. Samarasinghe S. Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition. – Crc Press, 2016.
116. Schultz T., Theisel H., Seidel H. P. Topological visualization of brain diffusion MRI data //IEEE Transactions on Visualization and Computer Graphics. – 2007. – T. 13. – №. 6. – C. 1496-1503.
117. Scott J. A. The lung scan and the abnormal chest X-ray: difficult diagnoses //Nuclear medicine communications. – 2004. – T. 25. – №. 11. – C. 1137-1141.
118. Sehgal A. et al. Automatic brain tumor segmentation and extraction in MR images //2016 Conference on Advances in Signal Processing (CASP). – IEEE, 2016. – C. 104-107.
119. Selvakumar J., Lakshmi A., Arivoli T. Brain tumor segmentation and its area calculation in brain MR images using K-mean clustering and Fuzzy C-mean algorithm //IEEE-International Conference On Advances In Engineering, Science And Management (ICAESM-2012). – IEEE, 2012. – C. 186-190.
120. Setayesh M., Zhang M., Johnston M. Improving edge detection using particle swarm optimisation //2010 25th International Conference of Image and Vision Computing New Zealand. – IEEE, 2010. – C. 1-8.

121. Setty Y. et al. Four-dimensional realistic modeling of pancreatic organogenesis //Proceedings of the National Academy of Sciences. – 2008. – T. 105. – №. 51. – C. 20374-20379.
122. Shalev-Shwartz S., Ben-David S. Understanding machine learning: From theory to algorithms. – Cambridge university press, 2014.
123. Sharma N., Aggarwal L. M. Automated medical image segmentation techniques //Journal of medical physics/Association of Medical Physicists of India. – 2010. – T. 35. – №. 1. – C. 3.
124. Sharma P., Diwakar M., Choudhary S. Application of edge detection for brain tumor detection //International Journal of Computer Applications. – 2012. – T. 58. – №. 16.
125. Shen D., Wu G., Suk H. I. Deep learning in medical image analysis //Annual review of biomedical engineering. – 2017. – T. 19. – C. 221-248.
126. Singh A. et al. Detection of brain tumor in MRI images, using combination of fuzzy c-means and SVM //2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN). – IEEE, 2015. – C. 98-102.
127. Singh A. K., Gupta B. A novel approach for breast cancer detection and segmentation in a mammogram //Procedia Computer Science. – 2015. – T. 54. – C. 676-682.
128. Singh I., Sanwal K., Praveen S. Breast cancer detection using two-fold genetic evolution of neural network ensembles //2016 International Conference on Data Science and Engineering (ICDSE). – IEEE, 2016. – C. 1-6.
129. Specht D. F. Probabilistic neural networks //Neural networks. – 1990. – T. 3. – №. 1. – C. 109-118.
130. Stosic Z., Rutesic P. An improved canny edge detection algorithm for detecting brain tumors in MRI images //International Journal of Signal Processing. – 2018. – T. 3.
131. Sudha S., Suresh G. R., Sukanesh R. Speckle noise reduction in ultrasound images by wavelet thresholding based on weighted variance //International journal of computer theory and engineering. – 2009. – T. 1. – №. 1. – C. 7.
132. Sun W., Zheng B., Qian W. Computer aided lung cancer diagnosis with deep learning algorithms //Medical imaging 2016: computer-aided diagnosis. – International Society for Optics and Photonics, 2016. – T. 9785. – C. 97850Z.
133. Suzuki K. (ed.). Artificial neural networks: methodological advances and biomedical applications. – BoD–Books on Demand, 2011.
134. Suzuki K. Computer-aided detection of lung cancer //Image-based computer-assisted radiation therapy. – Springer, Singapore, 2017. – C. 9-40.
135. Suzuki K. et al. Extraction of left ventricular contours from left ventriculograms by means of a neural edge detector //IEEE Transactions on Medical Imaging. –

2004. – T. 23. – №. 3. – C. 330-339.
136. Suzuki K. et al. Image-processing technique for suppressing ribs in chest radiographs by means of massive training artificial neural network (MTANN) //IEEE Transactions on medical imaging. – 2006. – T. 25. – №. 4. – C. 406-416.
  137. Suzuki K. Overview of deep learning in medical imaging //Radiological physics and technology. – 2017. – T. 10. – №. 3. – C. 257-273.
  138. Suzuki K., Horiba I., Sugie N. Efficient approximation of neural filters for removing quantum noise from images //IEEE transactions on signal processing. – 2002. – T. 50. – №. 7. – C. 1787-1799.
  139. Swanson K. R., Rostomily R. C., Alvord Jr E. C. A mathematical modelling tool for predicting survival of individual patients following resection of glioblastoma: a proof of principle //British journal of cancer. – 2008. – T. 98. – №. 1. – C. 113-119.
  140. Tosta T. A. A. et al. Application of Evolutionary Algorithms on Unsupervised Segmentation of Lymphoma Histological Images //2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS). – Ieee, 2017. – C. 89-94.
  141. Types of tumours - Canadian Cancer Society // <http://www.cancer.ca/en/region-selector-page/?url=%2fen%2fabout-us%2fpage-not-found%2f>, last accessed: 5 /5/ 2018.
  142. Umbaugh S. E. Computer imaging: digital image analysis and processing. – CRC press, 2005.
  143. Vajda S. et al. Feature selection for automatic tuberculosis screening in frontal chest radiographs //Journal of medical systems. – 2018. – T. 42. – №. 8. – C. 146.
  144. Verma V. S. et al. New morphological technique for medical image segmentation //2017 3rd International Conference on Computational Intelligence & Communication Technology (CICT). – IEEE, 2017. – C. 1-5.
  145. Viswanath K., Gunasundari R. Analysis and implementation of kidney stone detection by reaction diffusion level set segmentation using xilinx system generator on FPGA //VLSI Design. – 2015. – T. 2015.
  146. Wang C. Segmentation of multiple structures in chest radiographs using multi-task fully convolutional networks //Scandinavian Conference on Image Analysis. – Springer, Cham, 2017. – C. 282-289.
  147. Wang G. et al. Automatic brain tumor segmentation based on cascaded convolutional neural networks with uncertainty estimation //Frontiers in computational neuroscience. – 2019. – T. 13. – C. 56.
  148. Wang G. et al. Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks //International MICCAI brainlesion workshop. – Springer, Cham, 2017. – C. 178-190.

149. Wang P., Wei Z., Xiao L. Pure spatial rich model features for digital image steganalysis //Multimedia Tools and Applications. – 2016. – T. 75. – №. 5. – C. 2897-2912.
150. Weizhen S., Fei L., Qinzen Z. The applications of improved retinex algorithm for X-ray medical image enhancement //2012 International Conference on Computer Science and Service System. – IEEE, 2012. – C. 1655-1658.
151. Wu H. H. P. Patient information extraction in digitized X-ray imagery //Image and Vision Computing. – 2004. – T. 22. – №. 3. – C. 215-226.
152. Wu W. et al. Brain tumor detection and segmentation in a CRF (conditional random fields) framework with pixel-pairwise affinity and superpixel-level features //International journal of computer assisted radiology and surgery. – 2014. – T. 9. – №. 2. – C. 241-253.
153. Xiao X. et al. An automated segmentation method for lung parenchyma image sequences based on fractal geometry and convex hull algorithm //Applied Sciences. – 2018. – T. 8. – №. 5. – C. 832.
154. Xu X. W. et al. Development of an improved CAD scheme for automated detection of lung nodules in digital chest images //Medical Physics. – 1997. – T. 24. – №. 9. – C. 1395-1403.
155. Yassine S. T. et al. A new fast brain tumor extraction method based on NI-means and expectation maximization //2018 4th International Conference on Optimization and Applications (ICOA). – IEEE, 2018. – C. 1-5.
156. Yezzi A., Zöllei L., Kapur T. A variational framework for integrating segmentation and registration through active contours //Medical image analysis. – 2003. – T. 7. – №. 2. – C. 171-185.
157. Yuan X., Wu L., Peng Q. An improved Otsu method using the weighted object variance for defect detection //Applied Surface Science. – 2015. – T. 349. – C. 472-484.
158. Yue Y., Shi Z., Zhang Z. Image edge detection algorithm based on shearlet //J. Computer Application and Software. – 2014. – T. 31. – №. 4. – C. 227-230,249.
159. Zanaly E. A. et al. Determination of gray matter (GM) and white matter (WM) volume in brain magnetic resonance images (MRI) //International Journal of Computer Applications. – 2012. – T. 45. – №. 3. – C. 16-22.
160. Zeinali Y., Story B. A. Competitive probabilistic neural network //Integrated Computer-Aided Engineering. – 2017. – T. 24. – №. 2. – C. 105-118.
161. Zhao G. et al. Bayesian convolutional neural network based MRI brain extraction on nonhuman primates //Neuroimage. – 2018. – T. 175. – C. 32-44.
162. Zotin A. et al. Edge detection in MRI brain tumor images based on fuzzy C-means clustering //Procedia Computer Science. – 2018. – T. 126. – C. 1261-1270.
163. Zotin A. et al. Lung boundary detection for chest X-ray images classification

- based on GLCM and probabilistic neural networks //Procedia Computer Science. – 2019. – Т. 159. – С. 1439-1448.
164. Zotin A. et al. Techniques for medical images processing using shearlet transform and color coding //Computer Vision in Control Systems-4. – Springer, Cham, 2018. – С. 223-259.
  165. Zotin A. Fast algorithm of image enhancement based on multi-scale Retinex //Procedia Computer Science. – 2018. – Т. 131. – С. 6-14.
  166. Ματσόπουλος Γ. Κ. et al. Thoracic non-rigid registration combining self-organizing maps and radial basis functions. – 2015.
  167. Автандилов Г. Г. Медицинская морфометрия. – 1990.
  168. Егиев В. Н. и др. Сравнительная оценка тканевой реакции на имплантацию обычных полипропиленовых сеток и с фиксированными на них аутофибробластами //Вестник Российского университета дружбы народов. Серия: Медицина. – 2012. – №. 6.
  169. 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.
  170. Зотин А. Г. и др. Обнаружение опухоли мозга на основе мрт с применением метода нечеткой кластеризации С-средних //Медицина и высокие технологии. – 2018. – №. 1. – С. 20-28.
  171. Зотин А. Г. и др. Обработка и анализ медицинских изображений: обнаружение опухоли на основе МРТ //Сложные системы в экстремальных условиях. – 2018. – С. 88-91.
  172. Кенц А.С., Симонов К.В., Хамад Ю.А. Визуализация и контрастирование медицинских изображений //Медицина и высокие технологии. – 2019. – № 4. – С. 31-38.
  173. Кириллова С. В. и др. Вычислительная методика обработки медицинских изображений: выделение границ //Медицина и высокие технологии. – 2018. – №. 1. – С. 14-19.
  174. Кириллова С. В. и др. Вычислительная технология обработки медицинских изображений: выделение границ //Информационные и математические технологии в науке и управлении. – 2018. – №. 4 (12).
  175. Колпаков А. А., Казанцев А. А. Сравнительный анализ результатов применения протезов «титановый шелк» и полипропилена у больных с послеоперационными вентральными грыжами //Русский медицинский журнал. – 2015. – Т. 23. – №. 13.
  176. Никоненко А. Г. Введение в количественную гистологию //АГ Никоненко,

Ки ев:-Книга плюс. – 2013.

177. Симонов К. В. и др. Алгоритмы геометрического анализа медицинских изображений //Информатизация и связь. – 2019. – №. 4. – С. 95-101.
178. Симонов К. В. и др. Алгоритмы обнаружения и классификации визуальных данных //Информатизация и связь. – 2019. – №. 4. – С. 55-63.
179. Симонов К. В. и др. Алгоритмы обработки и анализа экспериментальных медицинских изображений //Медицина и высокие технологии. – 2019. – №. 2. – С. 54-60.
180. Симонов К. В., Зотин А. Г., Хамад Ю. А. Алгоритмы обнаружения и классификация патологии легких на рентгеновских снимках //Медицина и высокие технологии. – 2019. – №. 2. – С. 46-53.
181. Симонов К. В., Хамад Ю. А., Кенц А. С. Нейросетевые алгоритмы классификации патологии легких на рентгеновских снимках //Нейроинформатика, ее приложения и анализ данных: Материалы XXVI Всероссийского семинара. – Красноярск: ИВМ СО РАН, 2019. – С. 104-109.
182. Симонов, К. В., Зотин, А. Г., Хамад, Ю., Курако, М. А., & Черепанова, Т. В. (2019). Алгоритмы анализа экспериментальных медицинских данных // Труды Международной конференции «АПВПМ»-2019. – Новосибирск: ИВМиМГ СО РАН, 2019. – С. 448- 453.
183. Хамад Ю. А. и др. Алгоритмы обнаружения границ на низко-контрастных изображениях компьютерной томографии //Моделирование неравновесных систем-2018. – 2018. – С. 100-104.
184. Хамад Ю. А. и др. Вычислительная методика обработки медицинских изображений, используя вейвлет и нейросети // Медицина и высокие технологии. – 2018. – №. 3. – С. 5-13.
185. 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.
186. Хамад Ю. А., Симонов К. В., Кенц А. С. Алгоритмы сегментации и распознавания объектов на медицинских изображениях на основе шварц-преобразования и нейронных сетей // Информатизация и Связь. – 2020. – № 3. – С. 35-45.

**ПРИЛОЖЕНИЕ А – Программа для ЭВМ: «Сегментация и классификация локальных объектов (опухолей головного мозга) на изображениях МРТ»**

Программа для ЭВМ предназначена для выделения и описания объекта интереса с целью поддержки принятия диагностических решений специалистом-медиком. Разработанное алгоритмическое и программное обеспечение с высоким быстродействием и точностью выполняет сегментацию и классификацию обнаруженного объекта – локальную область (опухоль головного мозга).

Экстракция объекта (опухоль головного мозга) позволяет локализовать объем аномальных клеток в срезах снимков МРТ с использованием классификатора SVM и сегментации опухолевых клеток, чтобы оценить геометрические параметры объекта (опухоли), присутствующего в этой сегментированной области.

Извлеченные признаки на основе сегментированной области анализируются с использованием искусственной нейронной сети для отображения типа объекта (опухоли), т.е. для классификации опухоли как доброкачественной или злокачественной.

*Набор экспериментальных данных* – набор данных цифровых изображений (DICOM).

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

*Язык программирования:* MATLAB 2017.

*Операционная система:* Windows 7 или 10.

```

function Load_MRI_Image_Callback(hObject, eventdata, handles)
% hObject handle to Load_MRI_Image
[FileName,PathName] = uigetfile('*.*jpg;*.png;*.bmp','Pick an MRI 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('Brain MRI Image');
    handles.ImgData = P;
    guidata(hObject,handles);
end
% -----
function Brain_tumor_segmen_Callback(hObject, eventdata, handles)
% hObject handle to Brain_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 brain using Otsu
x=bcet(grayimage,100);
img = im2bw(x,0.45);
brain = imfill(img,8,'holes');
brain = uint8(255 * mat2gray(brain));
brain =output(brain);
% to remove extra size from normal brain
A= imresize(brain, [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_brain = imrotate(A,90);
normal_brain = imrotate( normal_brain,180);
sz=zeros(256,11);
A=cat(2,normal_brain,sz);
normal_brain = imrotate( A,180);
Norma_size_of_Brain=cat(2,normal_brain,sz);
% Combine detected tumor and non-infected area of brain using DWT
Brain_and_TumorAreas=fusion(Norma_size_of_Brain,Tumor);
boundbrain=Norma_size_of_Brain-Tumor;
% contours detection
boundbrain=edge(boundbrain,'canny',0.3);
Norma_size_of_Brain_edges=edge(brain,'canny',0.3);
axes(handles.axes2)
imshow(out);
axes(handles.axes3)
imshow(boundbrain);
hold on;
[B,L,N] = bwboundaries(Norma_size_of_Brain_edges);
for k=1:length(B),
boundary = B{k};
plot(boundary(:,2), boundary(:,1), 'white', 'LineWidth',1);
end
[B,L,N] = bwboundaries(boundbrain);
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_Brain-Tumor);
    axes(handles.axes4)
    imshow(Brain_and_TumorAreas);
    colormap(winter);
hold on;
[B,L,N] = bwboundaries(brain);
for k=1:length(B),
    boundary = B{k};
    plot(boundary(:,2), boundary(:,1), 'm', 'LineWidth',3);
end
[B,L,N] = bwboundaries(boundbrain);
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 brain and tumor and processing time
size_of_brain=img- BW2;
size_of_tumor = sum(Tumor(:));
set(handles.edit20,'string',size_of_tumor);
size_of_brain = (sum(size_of_brain(:)));
set(handles.edit21,'string',size_of_brain);
PerSizeTumor=(size_of_tumor/size_of_brain)*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 brain
%% 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 MRI 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);
% -----

```

**ПРИЛОЖЕНИЕ Б – Программа для ЭВМ: «Алгоритмическое и программное обеспечение обработки и анализа изображений компьютерной томографии и рентгенографии грудной клетки»**

Алгоритмическое и программное обеспечение предназначено для сегментации области легких и распознавания патологии с целью повышения скорости и точности скрининга патологий и оценки состояния пациента. Таким образом, рентгенологам предлагается система CAD (компьютерная диагностическая система), которая поддерживает вычислительные процедуры для обнаружения и контурирования областей легких на изображениях CXR (рентгеновские снимки), а также для классификации этих объектов (с патологией или без нее).

Разработанное алгоритмическое программное обеспечение позволяет описывать геометрию области легких, размер области и неровности формы с использованием методов сегментации, а затем извлекать 18 функций из изображения CXR с использованием матрицы оценки уровня серого (GLCM). Это позволяет классифицировать изображение CXR как нормальное или аномальное с использованием классификатора вероятностной нейронной сети (PNN).

*Базы данных* Montgomery County (США) и Shenzhen Hospital (Китай) на основе рентгеновских снимков.

*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.

Upload input image to GUI

```
[filename, pathname] = uigetfile('*.*', 'Pick a Image');
    if isequal(filename,0) || isequal(pathname,0)
        warndlg('User pressed cancel')
    else
        filename=strcat(pathname,filename);
        InputImage=imread(filename);
        InputImage= imresize(InputImage, [512 512]);
        axes(handles.axes1);
        imshow(InputImage);
        handles.InputImage=InputImage;
    end
% CXR segmentation and edge detection
function ProcessCXR_Callback(hObject, eventdata, handles)
I=getimage(handles.axes1);
I= imresize(I, [300 300]);
im = im2double(I);
size(im)
% Convert RGB to Gray via PCA
lab = rgb2lab(im);
f = 0;
wlab = reshape(bsxfun(@times,cat(3,1-f,f/2,f/2),lab),[],3);
[C,S] = pca(wlab);
S = reshape(S,size(lab));
S = S(:, :, 1);
gray = (S-min(S(:)))/(max(S(:))-min(S(:)));
gray1=rgb2gray(I);
Ifil2=medfilt2(gray1,[6,6]);
Ifil22= imresize(Ifil2, [300 300]);
hy = fspecial('sobel');
hx = hy';
Iy = imfilter(double(Ifil22), hy, 'replicate');
Ix = imfilter(double(Ifil22), hx, 'replicate');
% contours detection using ShearLet transform
gradmag = sqrt(Ix.^2 + Iy.^2);
    axes(handles.axes6);
    imshow(gradmag,[]);
    colormap(jet);
gradmag= imresize(gradmag, [512 512]);
% Morphological Closing
se = strel('disk',1);
close = imclose(gray,se);
% Complement Image
K= imcomplement(close);
% 2-D wavelet Decomposition using B-Spline
```

```

[cA,cH,cV,cD] = dwt2(K,'bior1.1');
%% Otsu thresholding on each of the 4 wavelet outputs
thresh1 = multithresh(cA);
thresh2 = multithresh(cH);
thresh3 = multithresh(cV);
thresh4 = multithresh(cD);
% Calculating new threshold from sum of the 4 otsu thresholds and dividing by 2
level = (thresh1 + thresh2 + thresh3 + thresh4)/2;
% balance contrast enhancement
Mean=110;
gray=bcet(gray,Mean);
axes(handles.axes2);
imshow(gray);
gray=mat2gray(gray);
% Fuzzy c Means
[bwfim1,level]=fcmthresh(gray,1);
BW2 = bwareaopen(bwfim1,400);
BWTEST = imcomplement(BW2);
figure,imshow(BWTEST)
BWTEST = imclearborder(BWTEST);
BW55 = bwareaopen(BWTEST ,400);
BBWW=sum( BW55(:));
A=imcrop(BW55, [0 0 150 300 ]);
B=imcrop(BW55, [151 0 300 300 ]);
outputmaskA=fillboundaries(A);
outputmaskB=fillboundaries(B);
AB=cat(2,outputmaskA,outputmaskB);
BWfulledge = edge(AB,'canny',0.3);
axes(handles.axes4);
imshow(AB);
hold on;
[B,L,N] = bwboundaries(BWfulledge);
for k=1:length(B),
    boundary = B{k};
    plot(boundary(:,2), boundary(:,1), 'green', 'LineWidth',2);
end
AB = imcomplement(AB);
out = imoverlay(im, AB, [1 0 1]);
axes(handles.axes3);
imshow(out);
axes(handles.axes5);
imshow(I);
colormap(jet);
hold on;
[B,L,N] = bwboundaries(BWfulledge);

```

```

for k=1:length(B),
    boundary = B{k};
    plot(boundary(:,2), boundary(:,1), 'blue', 'LineWidth',2);
end
% -----
%Function of Classifier probabilistic neural network (CPNN)
load ExtractedFeatures
A=1:20;
B=21:40;
P = [A B];
Tc = [1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2];
k=2; % k: number of regions
g=2; % g: number of GMM components
beta=1; % beta: unitary vs. pairwise
EM_iter=5; % max num of iterations
MAP_iter=5; % max num of iterations
file=getimage(handles.axes1);
file= imresize(file, [256 256]);
file=adaptivemedian(file);
figure,imshow(file,[]);
[Xk,GMMk,ShapeTexture]=image_kmeans(file,k,g);
PreProcessedImage(:,1)=file;
PreProcessedImage(:,2)=file;
PreProcessedImage(:,3)=file;
stats= gmmsegmentation(Xk,PreProcessedImage,GMMk,k,g,beta,EM_iter,MAP_iter,
ShapeTexture);
ShapeTexture=stats.ShapeTexture;
for i=1:40
    statsa=ExtractedFeature{i};
    ShapeTexturea=statsa.ShapeTexture;
    diff1(i)=corr2(stats.autoc,statsa.autoc);
    diff2(i)=corr2(stats.contr,statsa.contr);
    diff3(i)=corr2(stats.corm,statsa.corm);
    diff4(i)=corr2(stats.cprom,statsa.cprom);
    diff5(i)=corr2(stats.cshad,statsa.cshad);
    diff6(i)=corr2(stats.dissi,statsa.dissi);
    diff7(i)=corr2(stats.energ,statsa.energ);
    diff8(i)=corr2(stats.entro,statsa.entro);
    diff9(i)=corr2(stats.homom,statsa.homom);
    diff10(i)=corr2(stats.homop,statsa.homop);
    diff11(i)=corr2(stats.maxpr,statsa.maxpr);
    diff12(i)=corr2(stats.sosvh,statsa.sosvh);
    diff13(i)=corr2(stats.savgh,statsa.savgh);
    diff14(i)=corr2(stats.svarh,statsa.svarh);
    diff15(i)=corr2(stats.senth,statsa.senth);

```

```

diff16(i)=corr2(stats.dvarh,statsa.dvarh);
diff17(i)=corr2(stats.denth,statsa.denth);
diff18(i)=corr2(stats.inf1h,statsa.inf1h);
diff19(i)=corr2(stats.inf2h,statsa.inf2h);
diff19(i)=corr2(stats.indnc,statsa.indnc);
diff19(i)=corr2(stats.idmnc,statsa.idmnc);
diff20(i)=corr2(ShapeTexture,ShapeTexturea);
end
[val1 index1]=max(diff1);
[val2 index2]=max(diff2);
[val3 index3]=max(diff3);
[val4 index4]=max(diff4);
[val5 index5]=max(diff5);
[val6, index6]=max(diff6);
[val7 index7]=max(diff7);
[val8 index8]=max(diff8);
[val9 index9]=max(diff9);
[val10 index10]=max(diff10);
[val11 index11]=max(diff11);
[val12 index12]=max(diff12);
[val13 index13]=max(diff13);
[val14 index14]=max(diff14);
[val15 index15]=max(diff15);
[val16 index16]=max(diff16);
[val17 index17]=max(diff17);
[val18 index18]=max(diff18);
[val19 index19]=max(diff19);
[val20 index20]=max(diff20);
T = ind2vec(Tc);
spread = 1;
net = newpnn(P,T,spread);
A = sim(net,P)
Ac = vec2ind(A);
p1(1) = index20;
p1(2) = index1;
p1(3) = index2;
p1(4) = index3;
p1(5) = index4;
p1(6) = index5;
p1(7) = index6;
p1(8) = index7;
p1(9) = index8;
p1(10) = index9;
p1(11) = index10;
p1(12) = index11;

```

```

p1(13) = index12;
p1(14) = index13;
p1(15) = index14;
p1(16) = index15;
p1(17)= index16;
p1(18) = index17;
p1(19) = index18;
p1(20) = index19;
a = sim(net,p1)
ac = vec2ind(a);
disp(ac);
if ac==1
    set(handles.edit1,'String','Abnormal');
else
    set(handles.edit1,'String','Normal');
end
warndlg('Process completed');
%Function of image_kmeans
function [X GMM ShapeTexture]=image_kmeans(Y,k,g)
[m n temp]=size(Y);
if temp==3
    b=rgb2gray(Y);
    ShapeTexture=wlt4(b);
elseif temp==1
    ShapeTexture=wlt4(Y);
    Y1(:,:,1)=Y;
    Y1(:,:,2)=Y;
    Y1(:,:,3)=Y;
Y=Y1;
end
y=reshape(Y,[m*n 3]);
x=kmeans(y,k);
X=reshape(x,[m n]);
GMM=get_GMM(X,Y,g);
%Function of get_GMM
function GMM=get_GMM(X,Y,g)
k=max(X(:));
GMM=cell(k,1);
for i=1:k
    index=(X==i);
    Y1=Y(:,:,1);
    Y2=Y(:,:,2);
    Y3=Y(:,:,3);
    XX=[Y1(index) Y2(index) Y3(index)];
    GMM{i} = gmdistribution.fit(XX,g,'Regularize',1);

```

End

%Function of gmmsegmentation

function statsa=

gmmsegmentation(X,PreProcessedImage,GMM,k,g,beta,EM\_iter,MAP\_iter,ShapeTexture);

    Y=double(PreProcessedImage);

    [X,Y,GMM]=HMRF\_EM(X,Y,GMM,k,g,EM\_iter,MAP\_iter,beta);

    Y=Y\*100;

    Y=uint8(Y);

        Y=rgb2gray(Y);

    Y=double(Y);

    statsa = glcm(Y,0,ShapeTexture);

%Function of HMRF\_EM

function [X Y GMM]=HMRF\_EM(X,Y,GMM,k,g,EM\_iter,MAP\_iter,beta)

sum\_U=zeros(1,EM\_iter);

for it=1:EM\_iter

    % fprintf('Iteration: %d\n',it);

    %% update X

    [X sum\_U(it)]=MRF\_MAP(X,Y,GMM,k,g,MAP\_iter,beta,0);

    %% update GMM

    GMM=get\_GMM(X,Y,g);

        if it>=3 && std(sum\_U(it-2:it))<0.01

            break;

    end

end

Y=getbinary(Y,X)

Function of MRF\_MAP

function [X sum\_U]=MRF\_MAP(X,Y,GMM,k,g,MAP\_iter,beta,show\_plot)

    [m n temp]=size(Y);

    x=X(:);

    y=reshape(Y,[m\*n 3]);

    sum\_U\_MAP=zeros(1,MAP\_iter);

for it=1:MAP\_iter % iterations

    % fprintf(' Inner iteration: %d\n',it);

    U=zeros(m\*n,k);

    U1=U;

    U2=U;

    for l=1:k % all labels

        for c=1:g

            mu=GMM{1}.mu(c,:);

            Sigma=GMM{1}.Sigma(:,c);

            p=GMM{1}.PComponents(c);

                yi=bsxfun(@minus,y,mu);

                temp1=(yi\*inv(Sigma)).\*yi;

                temp1=sum(temp1,2)/2;

                temp1=temp1+log(sqrt(det(Sigma)));

```

    U1(:,1)=U1(:,1)+temp1*p;
end
    for ind=1:m*n % all pixels
    [i j]=ind2ij(ind,m);
    u2=0;
    if i-1>=1
        u2=u2+(1 ~ X(i-1,j))/2;
    end
    if i+1<=m
        u2=u2+(1 ~ X(i+1,j))/2;
    end
    if j-1>=1
        u2=u2+(1 ~ X(i,j-1))/2;
    end
    if j+1<=n
        u2=u2+(1 ~ X(i,j+1))/2;
    end
    U2(ind,1)=u2;
    end
end
U=U1+U2*beta;
[temp x]=min(U,[],2);
sum_U_MAP(it)=sum(temp(:));
X=reshape(x,m,n);
    if it>=3 && std(sum_U_MAP(it-2:it))<0.01
    break;
    end
end
sum_U=0;
for ind=1:m*n % all pixels
    sum_U=sum_U+U(ind,x(ind));
end
if show_plot==1
    figure;
    plot(1:it,sum_U_MAP(1:it),'r');
    title('sum U MAP');
    xlabel('MAP iteration');
    ylabel('sum U MAP');
    drawnow;
end
%Function of getbinary
function b=getbinary(a,X);
Centeroid=180;
a=uint8(a);
ag=rgb2gray(a);

```

```

[r c p]=size(ag);
for i=1:r
    for j=1:c
        data=ag(i,j);
        if data >Centeroid;
            X(i,j,1)=255;
            X(i,j,2)=255;
            X(i,j,3)=255;
        end
    end
end
end
b=X;
%Function of GLCM
function [out] = glcm(glcmin,pairs,ShapeTexture)
if ((nargin > 3) || (nargin == 0))
    error('Too many or too few input arguments. Enter GLCM and pairs.');
```

```

elseif ( (nargin == 3) )
    if ((size(glcmin,1) <= 1) || (size(glcmin,2) <= 1))
        error('The GLCM should be a 2-D or 3-D matrix.');
```

```

    elseif ( size(glcmin,1) ~= size(glcmin,2) )
        error('Each GLCM should be square with NumLevels rows and NumLevels cols');
```

```

    end
elseif (nargin == 1) % only GLCM is entered
    pairs = 0; % default is numbers and input 1 for percentage
    if ((size(glcmin,1) <= 1) || (size(glcmin,2) <= 1))
        error('The GLCM should be a 2-D or 3-D matrix.');
```

```

    elseif ( size(glcmin,1) ~= size(glcmin,2) )
        error('Each GLCM should be square with NumLevels rows and NumLevels cols');
```

```

    end
end
end
bdata=glcmin;
format long e
if (pairs == 1)
    newn = 1;
    for nglcm = 1:2:size(glcmin,3)
        glcm(:,:,newn) = glcmin(:,:,nglcm) + glcmin(:,:,nglcm+1);
        newn = newn + 1;
    end
elseif (pairs == 0)
    glcm = glcmin;
end
size_glcmin_1 = size(glcm,1);
size_glcmin_2 = size(glcm,2);
size_glcmin_3 = size(glcm,3);

```

```

% checked
out.autoc = zeros(1,size_glcm_3); % Autocorrelation: [2]
out.contr = zeros(1,size_glcm_3); % Contrast: matlab/[1,2]
out.corm = zeros(1,size_glcm_3); % Correlation: matlab
out.corrp = zeros(1,size_glcm_3); % Correlation: [1,2]
out.cprom = zeros(1,size_glcm_3); % Cluster Prominence: [2]
out.cshad = zeros(1,size_glcm_3); % Cluster Shade: [2]
out.dissi = zeros(1,size_glcm_3); % Dissimilarity: [2]
out.energ = zeros(1,size_glcm_3); % Energy: matlab / [1,2]
out.entro = zeros(1,size_glcm_3); % Entropy: [2]
out.homom = zeros(1,size_glcm_3); % Homogeneity: matlab
out.homop = zeros(1,size_glcm_3); % Homogeneity: [2]
out.maxpr = zeros(1,size_glcm_3); % Maximum probability: [2]
out.sosvh = zeros(1,size_glcm_3); % Sum of squares: Variance [1]
out.savgh = zeros(1,size_glcm_3); % Sum average [1]
out.svarh = zeros(1,size_glcm_3); % Sum variance [1]
out.senth = zeros(1,size_glcm_3); % Sum entropy [1]
out.dvarh = zeros(1,size_glcm_3); % Difference variance [4]
%out.dvarh2 = zeros(1,size_glcm_3); % Difference variance [1]
out.denth = zeros(1,size_glcm_3); % Difference entropy [1]
out.inf1h = zeros(1,size_glcm_3); % Information measure of correlation1 [1]
out.inf2h = zeros(1,size_glcm_3); % Informaiton measure of correlation2 [1]
%out.mxcch = zeros(1,size_glcm_3);% maximal correlation coefficient [1]
%out.invdc = zeros(1,size_glcm_3);% Inverse difference (INV) is homom [3]
out.indnc = zeros(1,size_glcm_3); % Inverse difference normalized (INN) [3]
out.idmnc = zeros(1,size_glcm_3); % Inverse difference moment normalized [3]
out.ShapeTexture=ShapeTexture;
glcm_sum = zeros(size_glcm_3,1);
glcm_mean = zeros(size_glcm_3,1);
glcm_var = zeros(size_glcm_3,1);
% the values of correlation that are provided by matlab.
u_x = zeros(size_glcm_3,1);
u_y = zeros(size_glcm_3,1);
s_x = zeros(size_glcm_3,1);
s_y = zeros(size_glcm_3,1);
% checked p_x p_y p_xplusy p_xminusy
p_x = zeros(size_glcm_1,size_glcm_3); % Ng x #glcms[1]
p_y = zeros(size_glcm_2,size_glcm_3); % Ng x #glcms[1]
p_xplusy = zeros((size_glcm_1*2 - 1),size_glcm_3); % [1]
p_xminusy = zeros((size_glcm_1),size_glcm_3); % [1]
% checked hxy hxy1 hxy2 hx hy
hxy = zeros(size_glcm_3,1);
hxy1 = zeros(size_glcm_3,1);
hx = zeros(size_glcm_3,1);
hy = zeros(size_glcm_3,1);

```

```

hxy2 = zeros(size_glcm_3,1);
for k = 1:size_glcm_3 % number glcms
    glcm_sum(k) = sum(sum(glcm(:,:,k)));
    glcm(:,:,k) = glcm(:,:,k)/glcm_sum(k); % Normalize each glcm
    glcm_mean(k) = mean2(glcm(:,:,k)); % compute mean after norm
    glcm_var(k) = (std2(glcm(:,:,k)))^2;
    for i = 1:size_glcm_1
        for j = 1:size_glcm_2
            out.contr(k) = out.contr(k) + (abs(i - j))^2.*glcm(i,j,k);
            out.dissi(k) = out.dissi(k) + (abs(i - j)*glcm(i,j,k));
            out.energ(k) = out.energ(k) + (glcm(i,j,k).^2);
            out.entro(k) = out.entro(k) - (glcm(i,j,k)*log(glcm(i,j,k) + eps));
            out.homom(k) = out.homom(k) + (glcm(i,j,k)/( 1 + abs(i-j) ));
            out.homop(k) = out.homop(k) + (glcm(i,j,k)/( 1 + (i - j)^2));
            % [1] explains sum of squares variance with a mean value;
            % the exact definition for mean has not been provided in
            out.sosvh(k) = out.sosvh(k) + glcm(i,j,k)*((i - glcm_mean(k))^2);
                %out.invdc(k) = out.homom(k);
            out.indnc(k) = out.indnc(k) + (glcm(i,j,k)/( 1 + (abs(i-j)/size_glcm_1) ));
            out.idmnc(k) = out.idmnc(k) + (glcm(i,j,k)/( 1 + ((i - j)/size_glcm_1)^2));
            u_x(k)      = u_x(k) + (i)*glcm(i,j,k); % changed 10/26/08
            u_y(k)      = u_y(k) + (j)*glcm(i,j,k); % changed 10/26/08
            % code requires that Nx = Ny
            % the values of the grey levels range from 1 to (Ng)
        end
    end
    out.maxpr(k) = max(max(glcm(:,:,k)));
end
% glcms have been normalized:
% The contrast has been computed for each glcm in the 3D matrix
% (tested) gives similar results to the matlab function
for k = 1:size_glcm_3
    for i = 1:size_glcm_1
        for j = 1:size_glcm_2
            p_x(i,k) = p_x(i,k) + glcm(i,j,k);
            p_y(i,k) = p_y(i,k) + glcm(j,i,k); % taking i for j and j for i
            if (ismember((i + j),[2:2*size_glcm_1]))
                p_xplusy((i+j)-1,k) = p_xplusy((i+j)-1,k) + glcm(i,j,k);
            end
            if (ismember(abs(i-j),[0:(size_glcm_1-1)]))
                p_xminusy((abs(i-j))+1,k) = p_xminusy((abs(i-j))+1,k) +...
                    glcm(i,j,k);
            end
        end
    end
end end end

```

```

% marginal probabilities are now available [1]
% p_xminusy has +1 in index for matlab (no 0 index)
% computing sum average, sum variance and sum entropy:
for k = 1:(size_glcm_3)
    for i = 1:(2*(size_glcm_1)-1)
        out.savgh(k) = out.savgh(k) + (i+1)*p_xplusy(i,k);
        % the summation for savgh is for i from 2 to 2*Ng hence (i+1)
        out.senth(k) = out.senth(k) - (p_xplusy(i,k)*log(p_xplusy(i,k) + eps));
    end
end
% compute sum variance with the help of sum entropy
for k = 1:(size_glcm_3)
    for i = 1:(2*(size_glcm_1)-1)
        out.svarh(k) = out.svarh(k) + (((i+1) - out.senth(k))^2)*p_xplusy(i,k);
        % the summation for savgh is for i from 2 to 2*Ng hence (i+1)
    end
end
% compute difference variance, difference entropy,
for k = 1:size_glcm_3
    for i = 0:(size_glcm_1-1)
        out.denth(k) = out.denth(k) - (p_xminusy(i+1,k)*log(p_xminusy(i+1,k) + eps));
        out.dvarh(k) = out.dvarh(k) + (i^2)*p_xminusy(i+1,k);
    end
end
% compute information measure of correlation(1,2) [1]
for k = 1:size_glcm_3
    hxy(k) = out.entro(k);
    for i = 1:size_glcm_1
        for j = 1:size_glcm_2
            hxy1(k) = hxy1(k) - (glcm(i,j,k)*log(p_x(i,k)*p_y(j,k) + eps));
            hxy2(k) = hxy2(k) - (p_x(i,k)*p_y(j,k)*log(p_x(i,k)*p_y(j,k) + eps));
        end
        hx(k) = hx(k) - (p_x(i,k)*log(p_x(i,k) + eps));
        hy(k) = hy(k) - (p_y(i,k)*log(p_y(i,k) + eps));
    end
    out.inf1h(k) = ( hxy(k) - hxy1(k) ) / ( max([hx(k),hy(k)]) );
    out.inf2h(k) = ( 1 - exp( -2*( hxy2(k) - hxy(k) ) ) )^0.5;
end
corm = zeros(size_glcm_3,1);
corp = zeros(size_glcm_3,1);
for k = 1:size_glcm_3
    for i = 1:size_glcm_1
        for j = 1:size_glcm_2
            s_x(k) = s_x(k) + (((i) - u_x(k))^2)*glcm(i,j,k);
            s_y(k) = s_y(k) + (((j) - u_y(k))^2)*glcm(i,j,k);
        end
    end
end

```

```

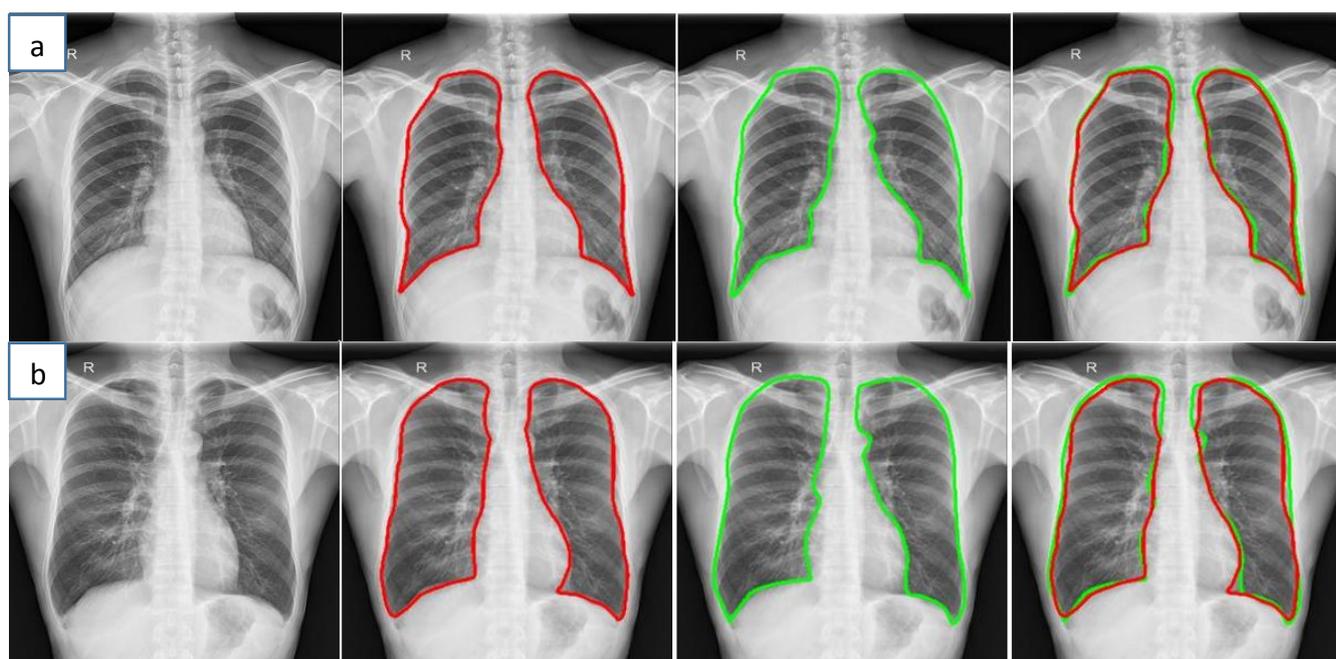
corp(k) = corp(k) + ((i)*(j)*glcm(i,j,k));
corm(k) = corm(k) + (((i) - u_x(k))*(j) - u_y(k))*glcm(i,j,k);
out.cprom(k) = out.cprom(k) + (((i + j - u_x(k) - u_y(k))^4)*...
    glcm(i,j,k));
out.cshad(k) = out.cshad(k) + (((i + j - u_x(k) - u_y(k))^3)*...
    glcm(i,j,k));
end
end
s_x(k) = s_x(k) ^ 0.5;
s_y(k) = s_y(k) ^ 0.5;
out.autoc(k) = corp(k);
out.corrp(k) = (corp(k) - u_x(k)*u_y(k))/(s_x(k)*s_y(k));
out.corm(k) = corm(k) / (s_x(k)*s_y(k));
end
%Function of Train probabilistic neural network (CPNN)
A=1:20;
B=21:40;
P = [A B];
Tc = [1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2];
T = ind2vec(Tc);
spread = 1;
net = newpnn(P,T,spread);
warndlg('Training Completed Sucessfully');
%Function of Balance contrast enhancement technique
function y=bcet(I,c)
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);

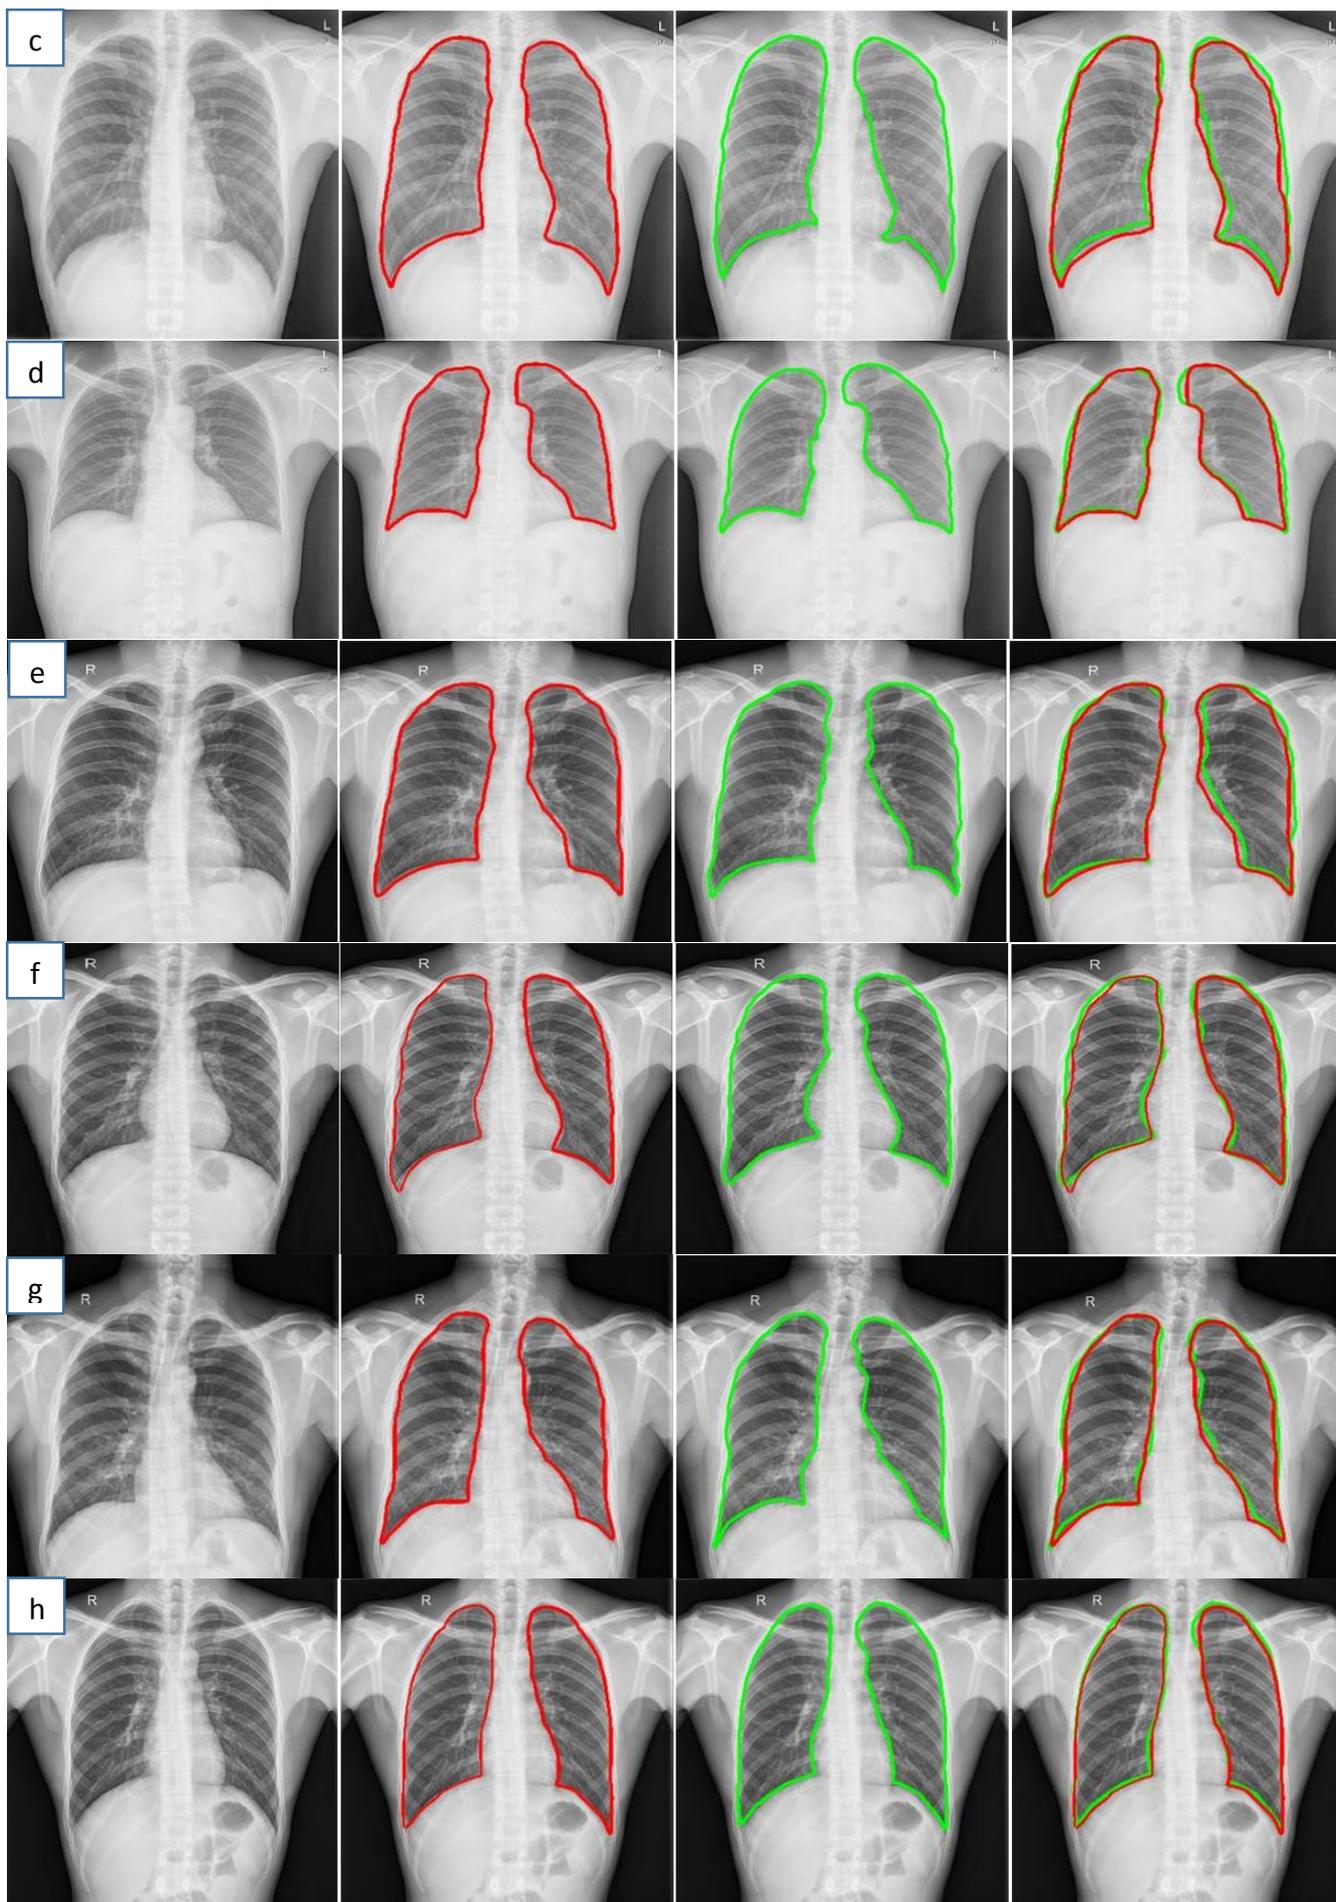
```

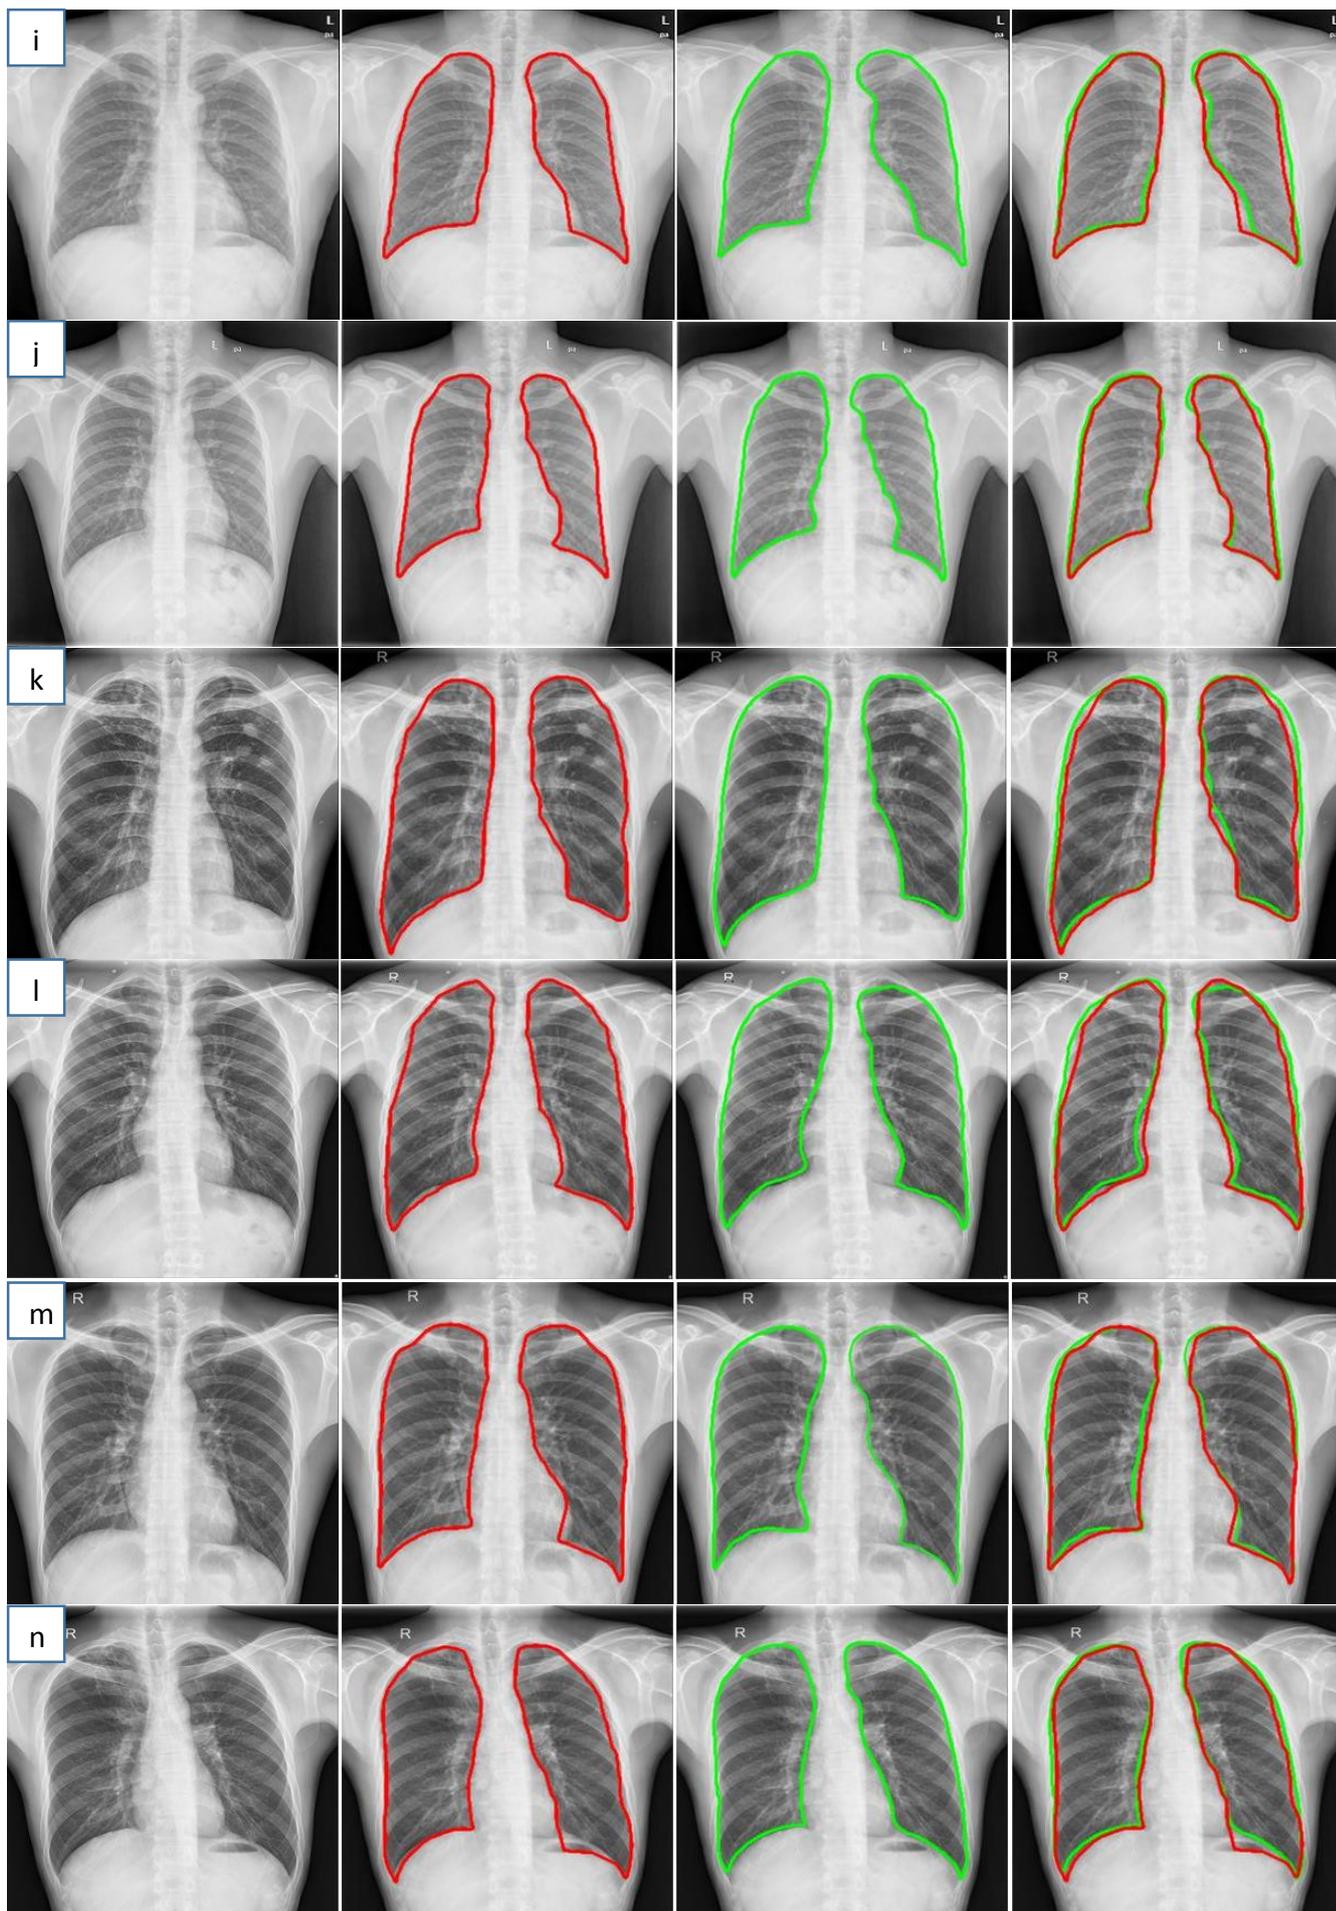
## ПРИЛОЖЕНИЕ В – Результаты экспериментальных исследований распознавания патологии и определения границ легких

Приведены результаты расчетов (рисунок В-1, рисунок В-2) на основе разработанного алгоритмического обеспечения (третья глава) по распознаванию патологии и определения границ легких в наборе данных MS и SH (пример: 20 пациентов). Зеленый контур обозначает стандартные границы легких (Ground truth), а красный контур создается с помощью нашей методики. Слева направо, первый столбец представляет исходные изображения, второй столбец показывает результаты метода сегментации (с красными краями), третий столбец – стандартные границы легких (с зелеными краями), а последний столбец – определение границ, сравнительно для нашего метода сегментации (красные) и стандартные (зеленые).

Показатели DSC,  $\Omega$  и точность также показаны в таблицах (В-1 и В-2) для каждой рентгенограммы грудной клетки. Получаем высококачественное описание границ области легкого и распознавание патологии. Предложенный алгоритм является быстрым и точным, не занимает большого дискового пространства для хранения эталонных изображений. Следовательно, разработанный алгоритм легко интегрировать в систему CAD.







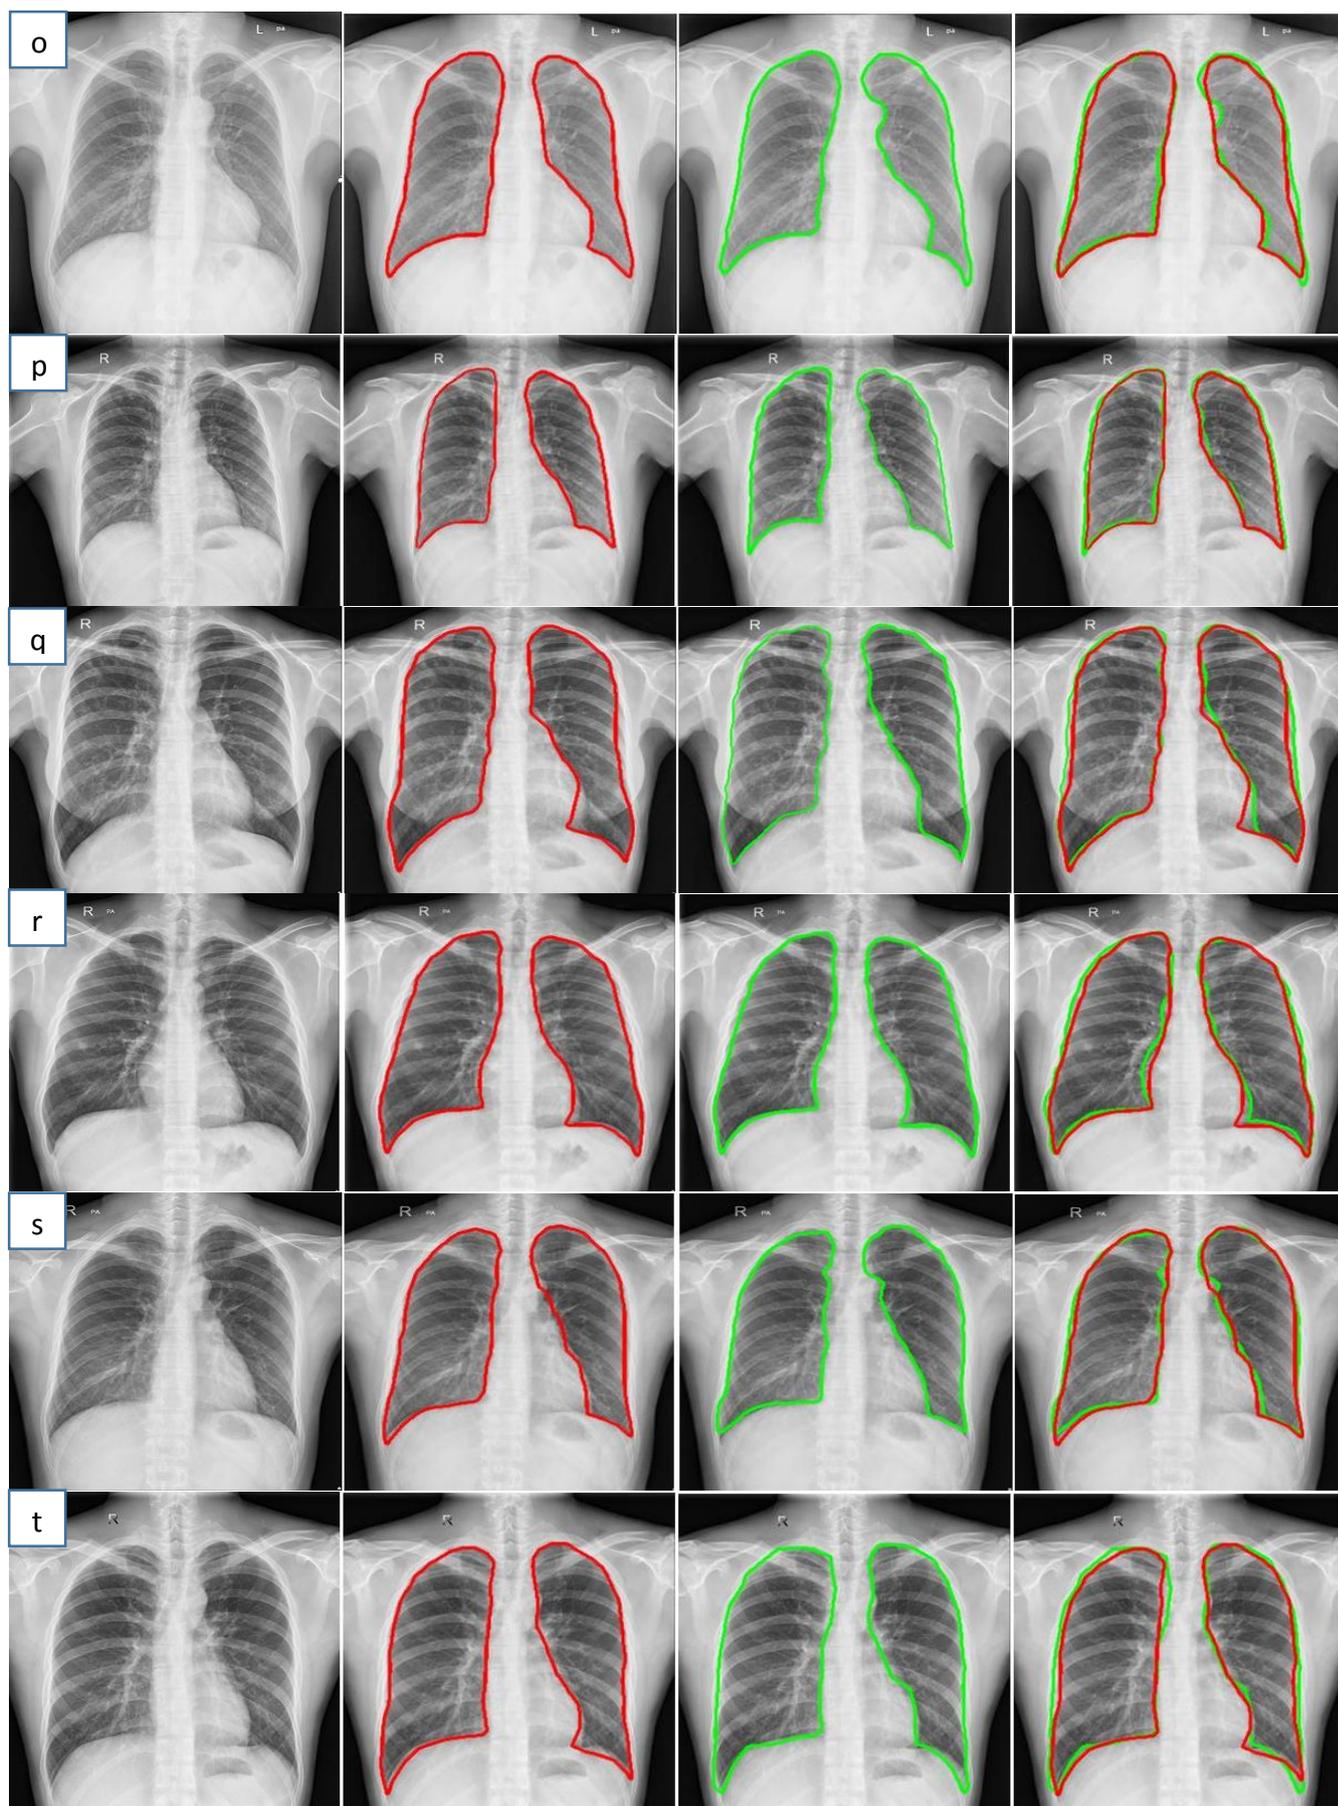
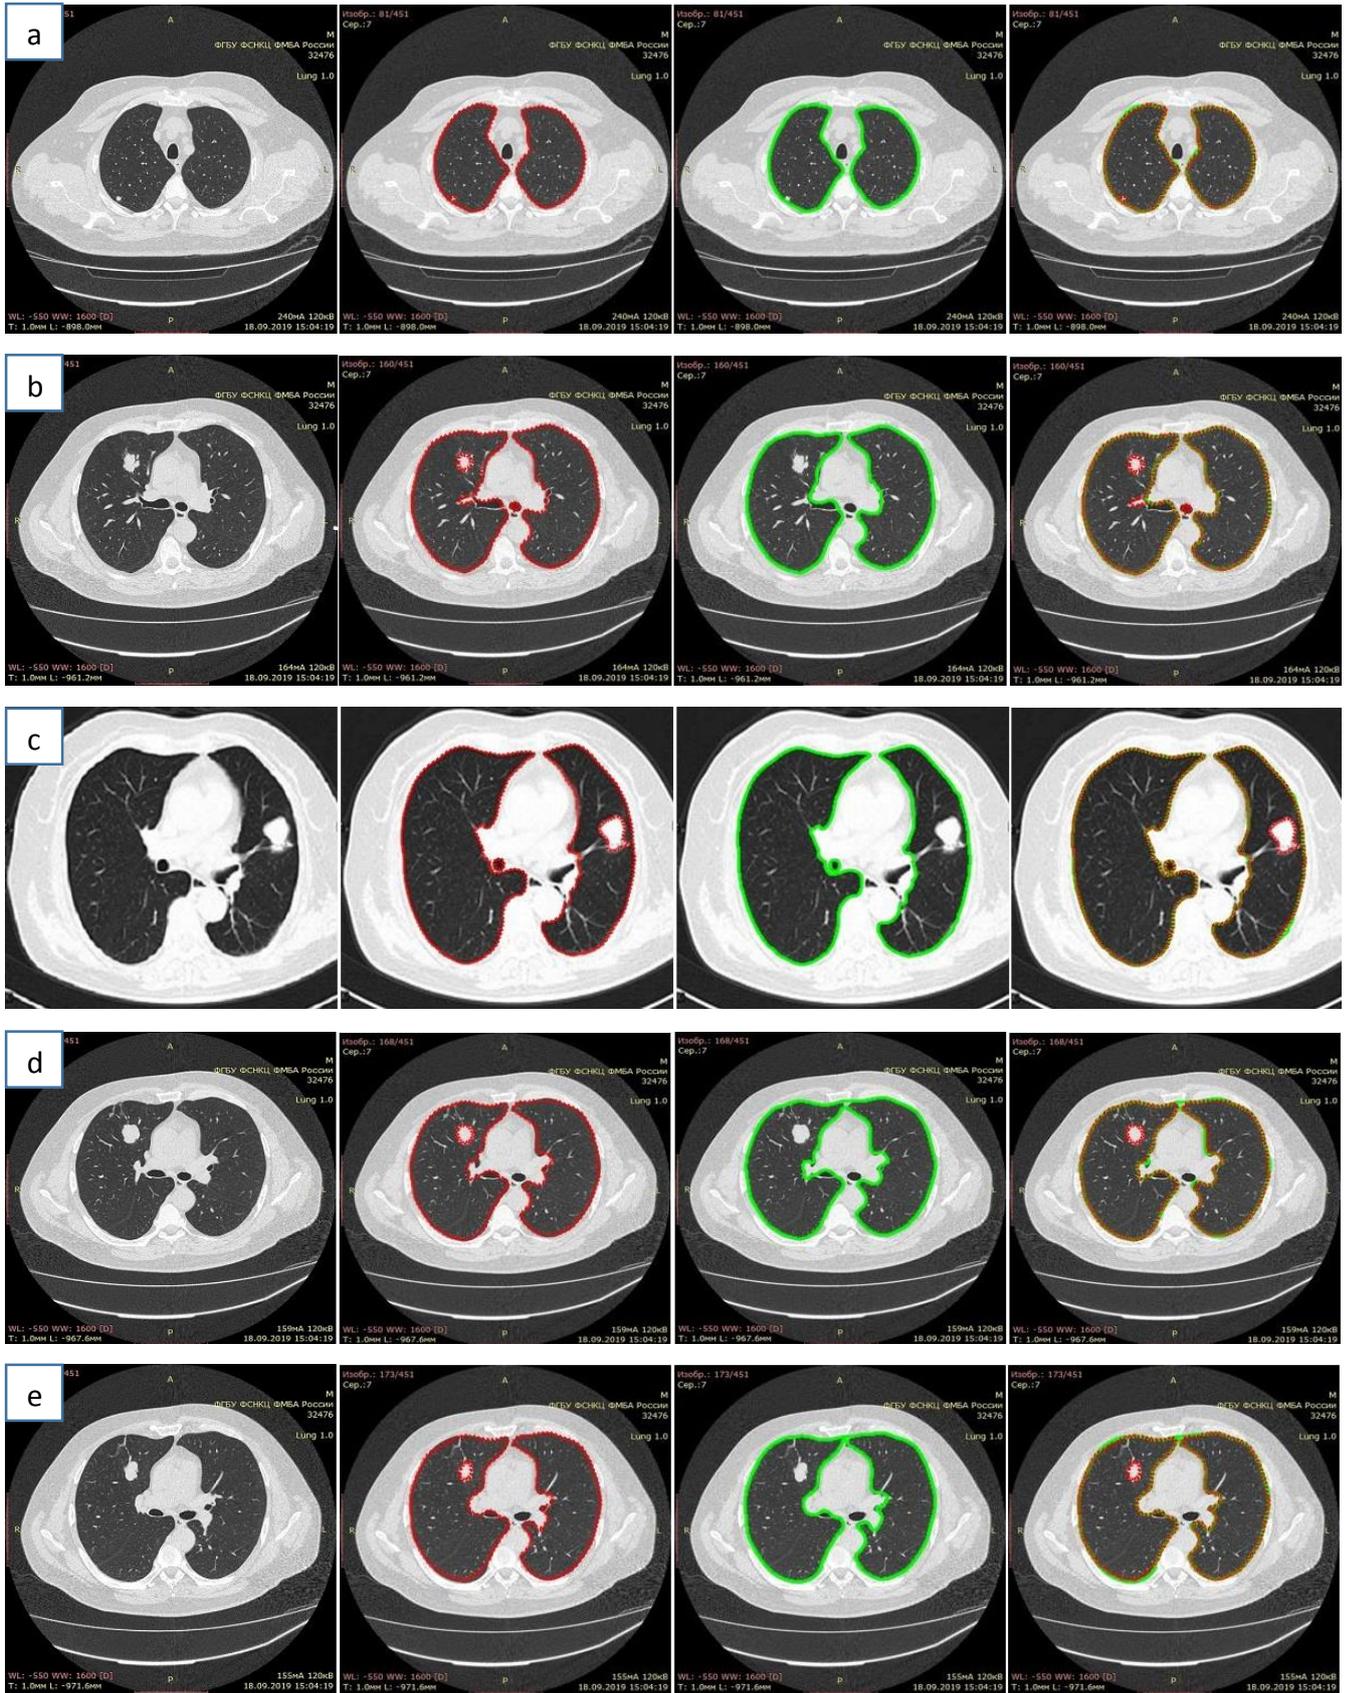


Рисунок В-1 – Результаты анализа рентгенографии грудной клетки (CXR)

Таблица В-1 – Статистические данные количественных оценок определения границ легких и распознавание патологии на снимках CXR

Пациенты	TP	TN	FP	FN	Точность	$\Omega$	DSC	Состояние пациента
пациент а	8480	7201	192	187	0,9764	0,9572	0,9781	п. без патологии
пациент b	8673	6810	155	422	0,9641	0,9376	0,9678	п. без патологии
пациент с	8978	6525	258	299	0,9653	0,9416	0,9699	п. без патологии
пациент d	6181	9334	152	203	0,9776	0,9457	0,9721	п. без патологии
пациент e	9455	6217	150	196	0,9784	0,9647	0,9820	п. без патологии
пациент f	8009	7352	191	363	0,9652	0,9353	0,9666	п. без патологии
пациент g	7908	7556	55	204	0,9835	0,9683	0,9839	п. без патологии
пациент h	7414	8329	148	169	0,9803	0,9590	0,9791	п. без патологии
пациент i	8556	6916	184	304	0,9694	0,9460	0,9723	п. без патологии
пациент j	7326	8218	69	258	0,9794	0,9573	0,9782	п. без патологии
пациент k	9369	6079	150	352	0,9685	0,9491	0,9739	п. с патологией
пациент l	8088	6937	406	258	0,9577	0,9241	0,9606	п. с патологией
пациент m	9125	6080	474	381	0,9468	0,9143	0,9552	п. с патологией
пациент n	8831	6587	240	402	0,9600	0,9322	0,9649	п. с патологией
пациент o	8157	7211	267	425	0,9569	0,9218	0,9593	п. с патологией
пациент p	6273	9256	121	425	0,9660	0,9199	0,9583	п. с патологией
пациент q	8565	6842	93	389	0,9697	0,9467	0,9726	п. с патологией
пациент r	8731	6386	350	213	0,9641	0,9394	0,9688	п. с патологией
пациент s	8650	6912	165	333	0,9690	0,9456	0,9720	п. с патологией
пациент t	9422	7058	190	240	0,9746	0,9564	0,9777	п. с патологией
<b>Общее количество</b>	<b>8309</b>	<b>7190</b>	<b>200</b>	<b>301</b>	<b>0,9686</b>	<b>0,9431</b>	<b>0,9707</b>	



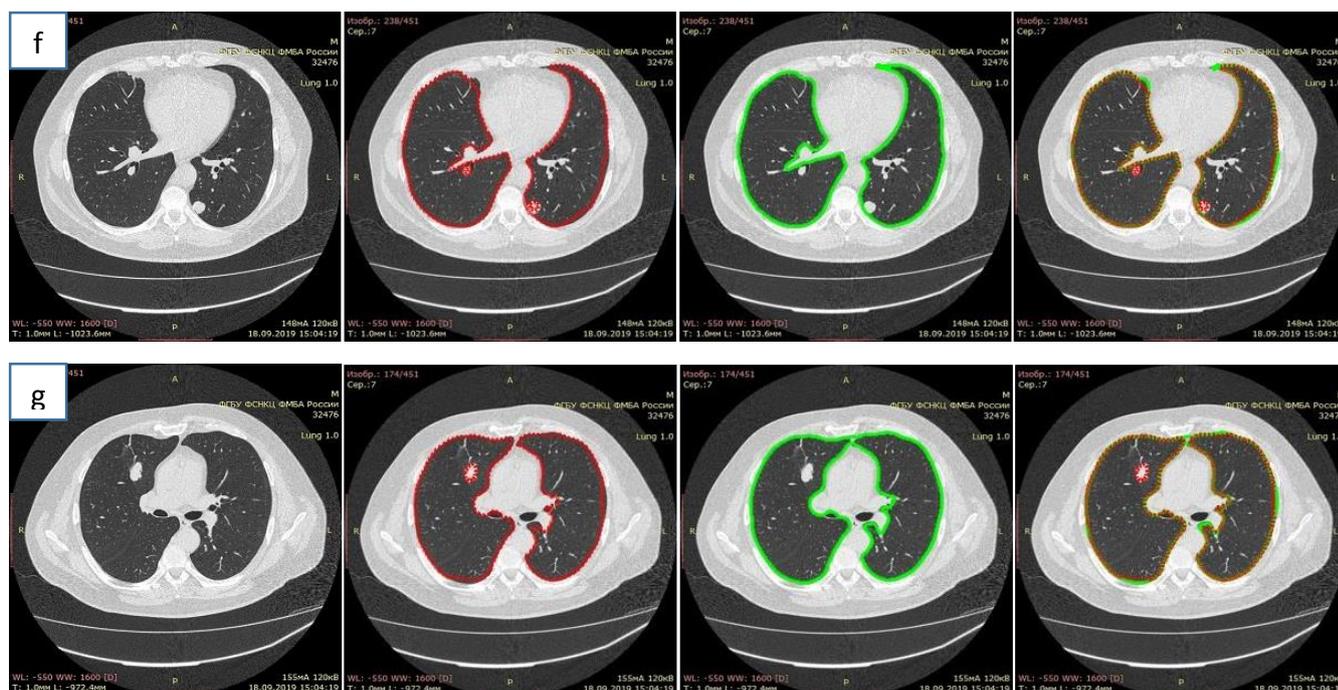


Рисунок В-2 – Результаты анализа данных компьютерной томографии (КТ)

Таблица В-2 – Статистические данные количественных оценок определения границ легких и распознавание патологии на снимках КТ

Пациенты	TP	TN	FP	FN	Точность	$\Omega$	DSC	Состояние пациента
пациент а	25401	236439	189	233	0,9984	0,9837	0,9918	п. с патологией
пациент b	76439	183575	1230	427	0,9937	0,9788	0,9893	п. с патологией
пациент с	40724	237293	1306	821	0,9924	0,9504	0,9745	п. с патологией
пациент d	43037	217825	2095	157	0,9914	0,9503	0,9745	п. с патологией
пациент e	45605	215577	1560	812	0,9910	0,9506	0,9747	п. с патологией
пациент f	43175	217687	923	759	0,9936	0,9625	0,9809	п. с патологией
пациент g	62175	317645	2163	520	0,9930	0,9586	0,9789	п. с патологией
<b>Общее количество</b>	<b>48079</b>	<b>232291</b>	<b>1352</b>	<b>532</b>	<b>0,9933</b>	<b>0,9623</b>	<b>0,9808</b>	