

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение высшего образования
АМУРСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
(ФГБОУ ВО «АмГУ»)

Институт компьютерных и инженерных наук
Кафедра математического анализа и моделирования
Направление подготовки – 01.04.02 Прикладная математика и информатика
Направленность (профиль) образовательной программы – Математическое и программное обеспечение информационных систем

ДОПУСТИТЬ К ЗАЩИТЕ
И.о. зав. кафедрой
_____ Н.Н. Максимова
« _____ » _____ 2024 г.

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

на тему: Программно-аналитическая система для нейросетевой диагностики морфологических особенностей рентгеновских снимков легких

Исполнитель студент группы 2101ом	_____	А.А. Синагатулин
	(подпись, дата)	
Руководитель профессор, д-р физ.-мат. наук	_____	А.Г. Масловская
	(подпись, дата)	
Руководитель научного содержания программы магистратуры профессор, д-р физ.-мат. наук	_____	А.Г. Масловская
	(подпись, дата)	
Нормоконтроль старший преподаватель	_____	А.Н. Дудин
	(подпись, дата)	
Рецензент	_____	А.Е. Ковтанюк
	(подпись, дата)	

Благовещенск 2024

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение высшего образования
АМУРСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
(ФГБОУ ВО «АмГУ»)

Институт компьютерных и инженерных наук
Кафедра математического анализа и моделирования

УТВЕРЖДАЮ

И.о. зав. кафедрой

_____ Н.Н. Максимова

« _____ » _____ 2024 г.

З А Д А Н И Е

К выпускной квалификационной работе студента Синагатулина Антона Андреевича

1. Тема выпускной квалификационной работы: Система программно-аналитической нейросетевой диагностики морфологических характеристик рентгеновских снимков легких

(утверждена приказом от 17.01.2024 № 64-уч)

2. Срок сдачи студентом законченной работы (проекта) 20.06.2024 г.

3. Исходные данные к выпускной квалификационной работе: рентгеновские снимки, модель нейросети для обучения, источники литературы.

4. Содержание выпускной квалификационной работы (перечень подлежащих разработке вопросов): диагностика рентгеновских снимков легких и обзор нейросетевых подходов для создания программно-аналитической системы.

5. Перечень материалов приложения: (наличие чертежей, таблиц, графиков, схем, программных продуктов, иллюстративного материала и т.п.) система программно-аналитической нейросетевой диагностики.

6. Консультанты по выпускной квалификационной работе (с указанием относящихся к ним разделов): рецензент – Масловская А.Г., профессор, д-р физ.-мат. наук; нормоконтроль – Дудин А.Н., старший преподаватель.

7. Дата выдачи задания: 29.02.2024 г.

Руководитель выпускной квалификационной работы: Масловская Анна Геннадьевна профессор, д-р физ.-мат. наук

Задание принял к исполнению (29.02.2024): _____ Синагатулин А.А.

РЕФЕРАТ

Магистерская работа содержит 118 с., 29 рисунков, 1 таблицу, 2 приложения, 36 источников.

АНАЛИЗ МЕТОДОВ ОБРАБОТКИ И АНАЛИЗА ИЗОБРАЖЕНИЙ ПРИ ДИАГНОСТИКЕ ЗАБОЛЕВАНИЙ ЛЕГКИХ, МЕТОДЫ ПРЕДОБРАБОТКИ И ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ, НЕЙРОННЫЕ СЕТИ, ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЕ, МУЛЬТИФРАКТАЛЬНЫЙ АНАЛИЗ, РЕГИСТРАЦИЯ ИЗОБРАЖЕНИЙ, ФИЛЬТРАЦИЯ ИЗОБРАЖЕНИЙ, ПАКЕТ IMAGE PROCESSING TOOLBOX, МАТЛАБ.

В работе исследованы современные методы обработки и анализа медицинских изображений для диагностики заболеваний легких. Основное внимание уделено разработке и апробации нейронной сверточной глубокогоуровневой сети ResNet50, реализованной в среде Matlab, а также методам предварительной обработки данных.

Цель работы – разработка эффективной системы классификации рентгеновских снимков легких, включающей алгоритмы предпроцессорной обработки и использование предварительно обученных нейронных сетей, для повышения точности диагностики заболеваний легких.

В магистерской работе представлено прикладное решение, включающее алгоритмы и методы обработки медицинских изображений с использованием пакета Image Processing Toolbox в системе Matlab. Проведен анализ эффективности различных методов сегментации и фильтрации изображений для улучшения качества диагностики.

Дополнительно работа содержит перспективы дальнейшего развития системы, включая модификацию алгоритмов предварительной обработки, расширение набора диагностических случаев, и проектирование новых нейронных сетей для повышения точности классификации изображений.

СОДЕРЖАНИЕ

Введение	6
1 Растровые изображения и методы их анализа в задачах медицинской диагностики	9
1.1 Цифровые изображения в медицине: математические методы и компьютерные средства для исследования особенностей	9
1.1.1 Способы регистрации изображений, используемые в клинической практике	9
1.1.2 Современная практика применения методов интеллектуального анализа изображений в медицине	19
1.2 Цифровые методы исследования патологий органов дыхания	24
1.2.1 Актуальные решения диагностики легочных заболеваний в России	24
1.2.2 Обзор подходов к регистрации данных при диагностике заболевания легких	29
1.3 Междисциплинарные исследования цифровых изображений, характеризующих состояния легких	32
1.3.1 Геометрическая обработка для анализа форм и структур на рентгеновских снимках	32
1.3.2 Статистические методы аномалий и паттернов	35
1.3.3 Применение алгоритмов машинного обучения и глубокого обучения нейросетей	42
2 Методы интеллектуального анализа растровых изображений	47
2.1 Методы фрактального и мультифрактального анализа	47
2.2 Методы, основанные на вейвлет-преобразованиях	50
2.3 Цифровая обработка изображений в MATLAB	56
2.4 Нейронные сети, специализированные пакеты и инструменты для работы с нейросетями в ППП MATLAB	69

3 Система тестовой преддиагностики заболеваний легких по данным рентгеновских снимков: реализация на платформе ППП MATLAB	73
3.1 Концептуальная постановка задачи разработки программно-аналитической системы	73
3.2 Проектирование архитектуры и формализация структуры системы	75
3.2.1 Разработка общей архитектуры программы в MATLAB	75
3.2.2 Определение основных компонентов системы	77
3.3 Систематизация и формальное описание алгоритмов интеллектуального анализа морфологических особенностей	84
3.3.1 Алгоритм мультифрактального вейвлет-анализа	84
3.3.2 Алгоритм работы нейросетевой модели. Ключевые особенности архитектуры сети ResNet50	86
3.3.3 Выбор и описание данных для обучения и валидация модели	92
3.4 Решение прикладных задач по проведению компьютерной преддиагностики заболеваний легких по данным рентгеновских изображений	94
3.4.1 Описание выборки и постановка вычислительного эксперимента	94
Заключение	100
Библиографический список	103
Приложение А	107
Приложение Б	109

ВВЕДЕНИЕ

Работа представляет результат апробации и расширения функционала нейронной сверточной глубокоуровневой сети ResNet50, реализованной в среде MATLAB, в приложении к решению задач классификации рентгеновских снимков при диагностике заболеваний легких человека. Для повышения качества диагностики система интеллектуального анализа дополнена процедурой предпроцессорной обработки цифровых изображений. Обучение сети проводилось с использованием снимков человеческих легких, полученных на флюорографическом аппарате, и рентгеновских снимков, размещенных в открытом доступе. Показано, что дополнительное обучение предварительно обученных глубоких нейронных сетей позволяет с высокой точностью выполнять задачи классификации объектов.

Применительно к диагностике заболеваний органов дыхания методологической базой систем, связанных с анализом цифровых изображений, служат алгоритмы прикладного статистического и фрактального анализа, концепции спектрального анализа, аппарат нейронных и нейро-нечетких сетей или гибридизации указанных подходов [1 – 12].

Так, например, в работе [2] предпринята реконструкция изображений компьютерной томографии с использованием двух архитектур нейронной сети для диагностики трех заболеваний: пневмоторакс, плевральный выпот, гидропневмоторакс. В [3] авторы оптимизировали время обработки изображений, инициализируемых в формате DICOM, для исследования на приборе магнитно-резонансной томографии. Оптимизатором времени в этом случае выступала нейронная сеть, которая снижала шум изображений, что позволило снизить время анализа снимков с 35 до 6 минут. Функционал автоматизированного пакета программного приложения по выявлению рака на ранней стадии представлен в [4], где авторы использовали предварительно обученную сеть VGG-19 и сеть долгой краткосрочной памяти (LSTM).

Авторы пришли к выводу, что совокупное использование двух нейронных сетей вместе с методами сегментации изображений позволяет установить точность классификации более 98,8%. В [5] предпринята попытка использования нейросети для исследования головного мозга на наличие и классификацию злокачественных и доброкачественных опухолей. В работе исследовалась точность обнаружения глиомы по изображениям магниторезонансной томографии на основе сверточных нейронных сетей в средах программирования Python и Matlab (с учетом сравнительного анализа возможностей сред). В работе [13] предложена сверточная нейросеть для прогнозирования рака легких по изображениям компьютерной томографии на основе оптимизации гиперпараметров. В дополнение можно отметить, что инструменты машинного обучения и нейронных сетей активно применяются при исследовании патологий органов дыхания человека на основе анализа нестационарных временных рядов, представляющих собой биомедицинские показатели. Например, в работе [14] реализован неинвазивный метод классификации четырех групп дыхательных звуков с использованием метода опорных векторов и сверточной нейронной сети. Результаты экспериментов двух методов были практически равны друг другу и способны классифицировать здоровые звуки и патологические с точностью 86%; помимо этого авторы показали возможность для предварительного диагностирования звуков дыхания.

Цель работы – разработка и реализация системы преддиагностики заболеваний легких на основе рентгеновских снимков, с применением методов интеллектуального анализа и глубокого обучения.

Объектом исследования является процесс автоматизированного анализа рентгеновских снимков для диагностики заболеваний легких с использованием методов глубокого обучения.

Предметом исследования являются алгоритмы и методы интеллектуального анализа изображений, включая предварительную обработку данных и обучение нейронных сетей, применительно к медицинской диагностике заболеваний легких.

Методы исследования включают применение математических и компьютерных алгоритмов для обработки и анализа изображений, а также обучение и тестирование нейронных сетей с использованием набора данных рентгеновских снимков легких.

Новизна работы заключается в разработке системы преддиагностики заболеваний легких, основанной на глубоком обучении и методах интеллектуального анализа изображений, что обеспечивает высокую точность классификации и диагностирования.

Практическая значимость работы заключается в создании инструмента, который позволяет автоматизировать процесс диагностики заболеваний легких, улучшить точность постановки диагнозов и снизить влияние человеческого фактора. Автоматизация процесса преддиагностики способствует повышению качества медицинского обслуживания и оперативности принятия медицинских решений.

Результаты исследовательской работы апробировались: на Региональных научно-практических конференциях «Молодёжь XXI века: шаг в будущее» 18.05.2023 – 22.05.2023 г.; и журнале Информатика и системы управления, 2024, № 2(80).

Работа состоит из трех глав. В первой главе магистерской диссертации рассмотрены теоретико-методологические основы систем интеллектуального анализа изображений в медицинской диагностике. Во второй главе описаны методы фрактального и мультифрактального анализа, вейвлет-преобразования и цифровой обработки изображений с использованием MATLAB. Третья глава посвящена разработке и реализации системы тестовой преддиагностики заболеваний легких на платформе MATLAB, включая описание архитектуры системы, алгоритмов интеллектуального анализа и результатов вычислительного эксперимента.

1 РАСТРОВЫЕ ИЗОБРАЖЕНИЯ И МЕТОДЫ ИХ АНАЛИЗА В ЗАДАЧАХ МЕДИЦИНСКОЙ ДИАГНОСТИКИ

1.1 Цифровые изображения в медицине: математические методы и компьютерные средства для исследования особенностей

1.1.1 Способы регистрации изображений, используемые в клинической практике

Цифровые изображения в медицине представляют собой графические данные, полученные с помощью различных медицинских оборудований, таких как компьютерные томографы (КТ), магнитно-резонансные томографы (МРТ), рентгеновские аппараты, ультразвуковые сканеры и другие.

Специфика цифровых изображений в медицине включает в себя несколько ключевых аспектов. Цифровые изображения медицинских сканов обладают высоким разрешением, что позволяет врачам детально исследовать внутренние структуры человеческого тела. Используются различные типы цифровых изображений, такие как рентгенограммы, МРТ-снимки, КТ-сканы, ультразвуковые изображения и т.д., каждый из которых имеет свои особенности и применения. С их помощью можно выявить различные патологии, определить степень поражения и следить за динамикой изменений [2].

Комплексность интерпретации цифровых изображений в медицине требует специальных знаний и опыта, так как интерпретация может быть сложной из-за множества деталей и нюансов на изображениях. В связи с конфиденциальностью медицинских данных цифровые изображения должны храниться и передаваться в безопасной форме, чтобы предотвратить несанкционированный доступ и утечку информации. Цифровые изображения часто интегрируются с другими технологиями, такими как программное обеспечение для анализа изображений, системы управления медицинскими данными (PACS), а также с медицинскими информационными системами (МИС), чтобы обеспечить эффективное управление и обработку медицинских данных.

Цифровые изображения в медицине являются важным инструментом для диагностики, мониторинга и лечения пациентов, и их использование продолжает развиваться с развитием технологий в медицинской сфере. Данные изображения требуют сложной обработки и анализа для выявления патологий и обеспечения точной диагностики. Математические методы играют ключевую роль в этом процессе, обеспечивая точность и надежность выделения структур и особенностей на изображениях. Они позволяют врачам и специалистам получить точное представление о состоянии пациента и определить дальнейшие шаги лечения.

Однако, для эффективного использования цифровых изображений требуется применение математических методов и компьютерных средств, которые помогают проанализировать особенности этих изображений и получить дополнительную информацию. Математические методы играют важную роль в обработке цифровых изображений в медицине. Это позволяет врачам выделять их особенности, изучать структуру и форму объектов, анализировать текстуры и цвета, а также определять наличие аномалий или изменений в тканях и органах. Применение математических методов включает такие техники, как фильтрация, сегментация, реконструкция и регистрация изображений [15].

Компьютерные средства также имеют важное значение при рассмотрении цифровых изображений в медицине. С их помощью можно обрабатывать изображения, повышая их качество, усиливая контрастность или разрешение, а также удаляя нежелательные артефакты или шумы. Кроме того, компьютерные средства предоставляют возможность объединять различные данные, создавать трехмерные модели или интерактивные визуализации, что помогает более понятно и наглядно представлять информацию, необходимую специалистам для анализа.

Благодаря применению математических методов и компьютерных средств, врачам становится доступным более точное и объективное исследование, что снижает риск ошибок и улучшает качество медицинской помощи. Таким образом, цифровые изображения в медицине требуют применения

математических методов и компьютерных средств для исследования и анализа их особенностей.

Это позволяет получить более точную информацию о состоянии пациента, улучшить качество диагностики и лечения, а также снизить время и затраты, связанные с обработкой и анализом изображений. В современной медицинской практике цифровые изображения стали неотъемлемой частью процессов диагностики, лечения и мониторинга заболеваний. Они предоставляют врачам уникальную возможность визуализации внутренних структур тканей и органов пациентов, что существенно облегчает процесс выявления патологий и разработки индивидуализированных планов лечения.

Математические методы играют ключевую роль в обработке и анализе цифровых изображений в медицине. Они обеспечивают точность и надежность при выделении структур и особенностей на изображениях. Фильтрация, морфологические операции, преобразования Фурье и вейвлет-анализ.

Методы, используемые для обработки медицинских изображений [16]:

- фильтрация применяется для удаления шумов с изображений, что позволяет получить более четкое представление о структурах и особенностях. Например, медицинские изображения могут содержать различные артефакты или шумы, которые могут затруднить визуализацию или анализ. Применение различных фильтров, таких как медианный фильтр или фильтр Гаусса, позволяет улучшить качество изображения, сделать его более четким и пригодным для последующего анализа;

- морфологические операции применяются для выделения объектов на изображении, таких как края и текстуры. Эти операции базируются на принципах математической морфологии и позволяют улучшить контрастность объектов на изображении, а также удалить ненужные детали или артефакты, которые могут мешать анализу;

- преобразования Фурье позволяют анализировать изображения в частотной области, что полезно для выявления особых паттернов и структур.

Например, на медицинских изображениях могут присутствовать различные текстуры или частотные характеристики, которые могут быть важными при диагностике определенных заболеваний. Преобразования Фурье помогают выделить эти характеристики и сделать их более заметными для врачей;

- вейвлет-анализ позволяет обнаруживать детали на разных уровнях разрешения, что важно при анализе медицинских изображений с разной степенью детализации. Этот метод позволяет обнаружить даже самые мелкие детали на изображении, что может быть критически важным при диагностике определенных патологий;

- сегментация изображений является важным этапом анализа медицинских изображений. Этот процесс позволяет разделить изображение на отдельные области или структуры, такие как органы или опухоли. Сегментация помогает в выделении интересующих областей для более детального изучения и диагностики, что в свою очередь способствует разработке эффективных планов лечения;

- автоматизация процесса диагностики с помощью классификации изображений играет важную роль в современной медицинской практике. Машинное обучение и нейронные сети позволяют классифицировать изображения на различные категории, что способствует более точной и быстрой диагностике. Например, изображения могут быть классифицированы на изображения с нормальными органами и с обнаруженными патологиями, что позволяет врачам проводить более точную диагностику и планировать соответствующее лечение [17].

Использование цифровых изображений в медицине сопряжено с определенными ограничениями и рисками, несмотря на их многочисленные преимущества. Вот некоторые из основных аспектов, которые следует учитывать:

Конфиденциальность данных: цифровые изображения медицинских сканов содержат конфиденциальную информацию о пациентах, включая их личные данные и медицинскую историю. Необходимо обеспечивать строгую

защиту этой информации от несанкционированного доступа, утечек данных и кибератак.

Безопасность передачи и хранения данных: передача и хранение цифровых медицинских изображений должны соответствовать высоким стандартам безопасности, чтобы предотвратить искажение, вмешательство или несанкционированный доступ к данным. Это включает в себя использование шифрования данных, защиту сетевых соединений и регулярное обновление систем безопасности.

Ошибки при анализе изображений: автоматическая обработка и анализ цифровых изображений могут быть подвержены ошибкам, которые могут привести к неправильным диагнозам и неправильному лечению. Например, алгоритмы компьютерного зрения могут неправильно интерпретировать данные из-за шумов или артефактов на изображении, что может привести к ошибочным выводам.

Зависимость от технологий и оборудования: использование цифровых изображений в медицине требует доступа к соответствующему оборудованию и программному обеспечению, а также квалифицированных специалистов для их обработки и анализа. Недоступность или неисправность оборудования может затруднить или задержать процесс диагностики и лечения.

Этические и юридические вопросы: использование цифровых изображений в медицине также поднимает ряд этических и юридических вопросов, связанных с соблюдением приватности пациентов, согласием на обработку медицинских данных, а также ответственностью за возможные ошибки или недочеты в диагностике и лечении.

В целом, хотя цифровые изображения в медицине предоставляют множество преимуществ, необходимо учитывать эти ограничения и риски, чтобы обеспечить безопасность, конфиденциальность и надежность использования таких данных в медицинской практике [18].

С развитием технологий и появлением новых методов анализа эффективность использования цифровых изображений в медицине будет

продолжать расти. Новые алгоритмы обработки и анализа изображений, а также развитие методов машинного обучения, открывают новые возможности для более точной диагностики и лечения различных заболеваний.

Цифровые изображения и математические методы их анализа играют ключевую роль в современной медицинской практике, обеспечивая врачам ценную информацию о состоянии пациентов и помогая повышать качество медицинского обслуживания. Их использование продолжит расширяться и улучшаться в будущем благодаря постоянному развитию технологий и методов анализа.

В клинической практике регистрация изображений предоставляет врачам ценную информацию о состоянии пациентов и помогает в диагностике различных заболеваний. Эти методы обеспечивают невероятно важные инструменты для визуализации внутренних органов и тканей, позволяя врачам не только обнаруживать патологии, но и следить за их динамикой во времени. Важно отметить, что существует множество методов регистрации изображений, каждый из которых обладает своими особенностями и преимуществами:

Магнитно-резонансная томография (МРТ) использует магнитные поля и радиоволны для создания детальных изображений внутренних органов и тканей. Этот метод обладает высокой разрешающей способностью и может использоваться для диагностики широкого спектра заболеваний, включая опухоли, сосудистые нарушения, заболевания центральной нервной системы и многие другие. МРТ особенно полезна для исследования мягких тканей и органов, таких как мозг, спинной мозг, мышцы и суставы [19]. МРТ использует сильные магнитные поля и радиоволны для создания подробных изображений внутренних органов и тканей. Атомы водорода в организме реагируют на магнитные поля, что позволяет получить изображение. Для проведения МРТ требуется специализированный сканер, который создает магнитные поля и излучает радиоволны. Полученные данные обрабатываются компьютером для создания изображения. МРТ обеспечивает высокую детализацию и контрастность изображений, особенно мягких тканей. Этот метод не использует

ионизирующее излучение и обычно безопасен для пациентов. МРТ может быть дорогим и требует специальной подготовки пациента. Также некоторые люди с имплантированными медицинскими устройствами или металлическими частицами не могут пройти МРТ из-за риска возможных осложнений.

Компьютерная томография (КТ): КТ использует рентгеновские лучи и компьютерную обработку данных для создания трехмерных изображений органов и тканей. Этот метод часто применяется для обнаружения опухолей, кровотечений, инфекций и других патологий во внутренних органах. КТ обеспечивает более высокое разрешение изображений по сравнению с рентгенографией, что делает его ценным инструментом в диагностике множества заболеваний. [20].

Ультразвуковая диагностика применяет звуковые волны высокой частоты для визуализации внутренних органов и тканей. Этот способ отличается безопасностью и отсутствием инвазивности, что обуславливает его широкое использование в разнообразных медицинских сферах, включая акушерство, кардиологию, ортопедию и травматологию. УЗИ часто используется для оценки состояния сердца, органов брюшной полости, мочевого пузыря, женских органов и многих других.

Ультразвуковая диагностика использует высокочастотные звуковые волны, которые отражаются от внутренних органов и тканей, создавая изображение [21]. Для УЗИ используются ультразвуковые датчики, которые наносят гель на кожу пациента и перемещаются по ней для получения изображений.

Преимуществом является безопасность и неинвазивность, не требует использования ионизирующего излучения, что делает ее безопасной для беременных и детей. Она также дешевле, чем МРТ и КТ, но имеет ограничения в визуализации тканей за костями или воздушными полостями. Кроме того, качество изображений может зависеть от опыта и квалификации оператора.

Рентген (рентгенография) основан на использовании рентгеновских лучей для создания изображений внутренних органов и тканей. Рентгеновские снимки

широко применяются в диагностике различных заболеваний, таких как переломы костей, опухоли и инфекции. Этот метод широко применяется для обнаружения различных патологий, таких как переломы костей, опухоли, инфекции и пневмонии. Однако рентгенография имеет свои ограничения, включая невозможность получения подробных изображений мягких тканей.

Рентгенография использует рентгеновские лучи, которые проходят через тело пациента и регистрируются на пленке или детекторе. Ткани различной плотности поглощают лучи по-разному, что создает изображение внутренних структур. Для проведения рентгенографии используются специальные аппараты, включая рентгеновские трубки и детекторы излучения. Изображение может быть двумерным (обычная рентгенограмма) или трехмерным (компьютерная томография).

Преимуществом является быстрая, относительно недорогая и широкодоступная. Она позволяет обнаруживать множество патологий, включая переломы, опухоли и инфекции. Рентгенография имеет ограничения в визуализации мягких тканей, таких как мышцы и органы, из-за их низкой поглощающей способности рентгеновских лучей. Также существует потенциальный вред от излучения, особенно при частом использовании. Врачи учитывают все факторы при принятии решения о том, какой метод регистрации изображений будет наиболее эффективным для конкретного пациента.

Цифровая рентгенография использует цифровые датчики для регистрации рентгеновских изображений. Позволяет получать изображения с более высоким разрешением и меньшим временем обработки. Кроме того, важно учитывать, что каждый из этих методов имеет свои особенности и потенциальные риски, связанные с применением их в клинической практике. Например, рентгенография и компьютерная томография используют ионизирующее излучение, которое может повысить риск развития рака при длительном и частом использовании. В то время как МРТ и ультразвуковая диагностика, как правило, считаются безопасными методами, не связанными с ионизирующим излучением, однако они также могут иметь свои ограничения и противопоказания, например,

при наличии имплантатов, которые могут быть чувствительны к магнитным полям.

Важно отметить, что эти методы часто используются в комбинации для получения наиболее полной информации о состоянии пациента. Например, магнитно-резонансная томография может быть дополнена контрастным усилением для улучшения визуализации опухолей или других патологий, а компьютерная томография может использоваться для быстрого сканирования и определения поражений в костях или органах с большей плотностью.

Критическое понимание сил и ограничений каждого из этих методов позволяет медицинским специалистам принимать информированные решения в интересах пациентов и обеспечивать им высококачественное медицинское обслуживание. Однако выбор конкретного метода зависит от множества факторов, включая клиническую ситуацию, доступные ресурсы и потребности пациента. Поэтому врачи должны обладать глубоким пониманием каждого метода и учитывать их преимущества и ограничения при принятии решения о диагностике и лечении пациентов.

Эти методы регистрации изображений представляют лишь часть многообразия инструментов, доступных в современной клинической практике. Выбор конкретного метода зависит от характеристик пациента, целей диагностики и доступных ресурсов. Каждый метод имеет свои преимущества и ограничения, и выбор оптимального инструмента играет ключевую роль в обеспечении качественного медицинского обслуживания.

Позитронно-эмиссионная томография (ПЭТ): использует радиоактивные маркеры для визуализации метаболических процессов в организме. Применяется в онкологии для оценки раковых опухолей. Одним из самых широко используемых методов визуализации является рентгенография. Она давно используется как метод регистрации изображений в медицине. Её основа заключается в использовании рентгеновских лучей для создания изображений внутренних органов и тканей. Этот метод широко применяется в клинической практике для диагностики множества патологий, таких как переломы костей,

опухоли, инфекции, пневмония и другие. Благодаря своей доступности и относительной не большой цене, рентгенография используется для скрининга, выявления и мониторинга различных состояний у пациентов всех возрастов.

Рентгенография легких — это часто используемый метод для диагностики различных патологий дыхательной системы, таких как пневмония, туберкулез, опухоли и другие. Рассмотрим её преимущества и недостатки в контексте анализа снимков легких. Преимущества рентгенографии легких является относительно быстрой и доступной процедурой, что позволяет быстро получить изображение для начальной оценки состояния пациента. В сравнении с другими методами, такими как компьютерная томография (КТ) или магнитно-резонансная томография (МРТ), рентгенография обычно стоит дешевле, что делает её более доступной для пациентов. Рентгенография легких может обнаружить различные патологии, такие как пневмония и опухоли, и широко применяется в клинической практике. Рентгенография обеспечивает ограниченную детализацию изображений, что может затруднить точную диагностику некоторых состояний, особенно в случае мелких изменений или мягких тканей.

Ограниченная способность к диагностике не может позволить обнаружить некоторые патологии, такие как ранние стадии рака или мелкие опухоли, могут быть трудно обнаружить с помощью рентгенографии легких. Ионизирующее излучение может повышать риск для пациентов, особенно при частом использовании или необходимости проведения серий снимков [22].

В целом, рентгенография легких остается важным инструментом в диагностике дыхательных заболеваний благодаря своей доступности. Однако она может быть ограничена в своей способности обнаруживать некоторые патологии из-за недостаточной детализации изображений и риска излучения. В некоторых случаях может потребоваться дополнительное обследование, такое как КТ или МРТ, для более точной диагностики.

Каждый из перечисленных методов имеет свои уникальные преимущества и ограничения в контексте анализа снимков легких. Выбор конкретного метода

зависит от клинической ситуации, доступности оборудования и предпочтений врача. Важно внимательно рассмотреть все аспекты при принятии решения о методе обследования для каждого пациента.

1.1.2 Современная практика применения методов интеллектуального анализа изображений в медицине

В медицинской диагностике значительное внимание уделяется разработке и применению различных методов регистрации данных для выявления и оценки заболеваний легких. Среди них особое место занимают методы компьютерной диагностики, которые позволяют получить детальное представление о состоянии легких и обнаружить патологии на ранних стадиях.

В данной главе мы рассмотрим различные методы регистрации данных при диагностике легочных заболеваний, а также более подробно остановимся на методах компьютерной диагностики. Будут проанализированы основные принципы работы каждого метода, их преимущества и ограничения, а также рассмотрены актуальные исследования и практические примеры применения. Этот обзор поможет лучше понять современные подходы к диагностике заболеваний легких и внести вклад в развитие эффективных методов регистрации и анализа данных в этой области медицины [27].

Клинический осмотр и анамнез включает в себя сбор медицинской истории пациента, а также проведение физикального обследования легких врачом. Клинический осмотр является одним из первичных методов диагностики легочных заболеваний. В ходе осмотра врач оценивает общее состояние пациента, а также проводит физикальное обследование легких, аускультацию и перкуссию. Этот подход позволяет выявить симптомы, такие как кашель, одышка, хрипы и другие, которые могут указывать на наличие заболевания. Сбор анамнеза позволяет выявить факторы риска, такие как курение, профессиональные вредности, аллергии и другие заболевания, которые могут быть связаны с легочными проблемами.

Функциональные тесты легких представляют собой важный метод диагностики легочных заболеваний, позволяющий оценить объемы и скорости

дыхания, объемы легких, обмен газов и другие параметры функции дыхания. Спирометрия, например, измеряет объемы и скорости вдоха и выдоха, что помогает выявить обструктивные и ограничительные нарушения. Главным преимуществом функциональных тестов является их высокая точность и возможность выявления легочных расстройств на ранних стадиях. Однако они могут быть технически сложными для выполнения и требуют специального оборудования и подготовки пациента. Кроме того, они могут быть непригодны для определения точной причины дыхательной недостаточности.

Пациентам могут предлагаться образовательные программы о вреде курения, воздействии загрязнения воздуха и других факторов на здоровье легких. Обучение о методах предупреждения заболеваний и правильном использовании лекарств также важно. Преимущества образовательных программ заключаются в их способности повысить осведомленность пациентов о факторах риска и методах профилактики, что может привести к улучшению соблюдения рекомендаций по лечению и управлению заболеванием. Эти программы также могут снизить вероятность возникновения осложнений и улучшить качество жизни пациентов. Однако эффективность образовательных программ может быть ограничена недостаточной мотивацией пациентов или недостаточной доступностью к информации. Также важно учитывать индивидуальные особенности каждого пациента при проведении образовательных мероприятий.

Иммунологические тесты могут использоваться для обнаружения антител или белков, связанных с различными легочными заболеваниями, такими как туберкулез или астма. Иммунологические тесты включают их высокую чувствительность и специфичность, что позволяет точно определить наличие или отсутствие инфекции или воспаления в легких. Эти тесты могут быть особенно полезны при выявлении заболеваний, которые трудно диагностировать по клиническим симптомам или при использовании других методов диагностики. Однако ограничениями иммунологических тестов могут быть их стоимость, необходимость специального оборудования и время, необходимое

для получения результатов. Кроме того, некоторые тесты могут давать ложноположительные или ложноотрицательные результаты, что требует дополнительной проверки.

Биомаркеры и генетические тесты иомаркеры представляют собой передовые методы диагностики и исследования легочных заболеваний. Это могут быть различные молекулы, такие как белки, гены или метаболиты, которые изменяются в ответ на наличие или развитие конкретного заболевания.

Генетические тесты направлены на выявление наследственных мутаций, которые могут быть связаны с развитием легочных заболеваний. Тесты включают их высокую чувствительность и специфичность, что позволяет точно определить наличие или риск развития определенных легочных заболеваний. Эти методы могут быть особенно полезны при выявлении наследственных форм заболеваний и определении индивидуального риска у пациентов. Однако ограничениями могут быть их высокая стоимость, необходимость специальной подготовки образцов и обработки данных, а также необходимость дополнительной проверки результатов.

С развитием технологий в области медицинской диагностики становится возможным использование различных сенсорных устройств для мониторинга состояния пациентов с заболеваниями легких. Эти устройства могут включать портативные приборы для измерения уровня кислорода в крови (пульсоксиметры), а также устройства для мониторинга дыхания и его параметров.

Преимущества сенсорных устройств включают их компактность, портативность и возможность длительного мониторинга в реальном времени. Эти устройства могут быть особенно полезны для пациентов с хроническими легочными заболеваниями, такими как ХОБЛ или астма, позволяя им отслеживать состояние своих легких в повседневной жизни.

Однако ограничениями сенсорных устройств могут быть их ограниченная точность по сравнению с более традиционными методами диагностики, а также необходимость правильной калибровки и использования. Кроме того, некоторые

из них могут быть недоступны для широкого круга пациентов из-за своей стоимости.

Телемедицина и мобильные приложения становятся все более распространенными средствами мониторинга состояния здоровья пациентов с легочными заболеваниями. Консультации позволяют пациентам получать консультации в реальном времени без необходимости посещения клиники. Мобильные приложения для мониторинга здоровья могут предоставлять пациентам инструменты для отслеживания симптомов, приема лекарств, измерения функции дыхания и других параметров.

Преимущества телемедицины и мобильных приложений включают их удобство, доступность и возможность повышения активности пациентов в уходе за своим здоровьем. Эти инструменты могут помочь улучшить соблюдение рекомендаций по лечению, управлению заболеванием и своевременному обращению за медицинской помощью.

Однако среди ограничений телемедицины и мобильных приложений можно выделить необходимость доступа к интернету и соответствующему оборудованию, а также вопросы конфиденциальности данных и качества предоставляемой информации.

Таким образом, телемедицина и мобильные приложения представляют собой перспективные инструменты для улучшения мониторинга и управления легочными заболеваниями, однако их использование требует внимательного подхода и дополнительных исследований.

Инструментальные методы включают в себя различные виды образовательной диагностики, такие как рентгенография, компьютерная томография (КТ), магнитно-резонансная томография (МРТ), позитронно-эмиссионная томография (ПЭТ), бронхоскопия, биопсия и другие.

Инструментальные методы диагностики заболеваний легких представляют собой широкий спектр технологий, которые играют важную роль в выявлении и оценке различных патологий этого органа. Рентгенография, компьютерная томография (КТ), магнитно-резонансная томография (МРТ),

позитронно-эмиссионная томография (ПЭТ), бронхоскопия, биопсия и другие методы предоставляют врачам разнообразные инструменты для диагностики и оценки состояния легких.

Каждый из этих методов имеет свои преимущества и ограничения. Например, рентгенография является доступным и относительно быстрым методом, но ее способность выявлять мелкие изменения ограничена. В то время как КТ и МРТ обладают более высокой чувствительностью и специфичностью, но требуют больше времени и ресурсов для проведения и анализа результатов. ПЭТ в сочетании с КТ позволяет дополнительно оценить функциональные аспекты легочных патологий, что делает этот метод особенно ценным для обнаружения и мониторинга онкологических процессов. Бронхоскопия и биопсия позволяют получить детальную информацию о состоянии дыхательных путей и легочной ткани, что особенно важно для диагностики различных заболеваний.

В целом, инструментальные методы диагностики легочных заболеваний играют ключевую роль в раннем выявлении, оценке степени тяжести и выборе оптимального лечения для пациентов. Они обеспечивают врачей информацией, необходимой для принятия обоснованных решений, улучшая качество медицинского ухода и повышая шансы на успешное выздоровление пациентов. Однако важно помнить, что выбор метода диагностики должен быть обусловлен индивидуальными особенностями пациента, характером заболевания и доступностью ресурсов.

1.2 Цифровые методы исследования патологий органов дыхания

1.2.1 Актуальные решения диагностики легочных заболеваний в России

В современной России диагностика легочных заболеваний представляет собой сложную и многоаспектную проблему, для решения которой применяются различные методы и технологии. Важным элементом в этом процессе остаются рентгеноскопия и флюорография, которые, несмотря на некоторые ограничения, по-прежнему играют значимую роль в первичной диагностике легочных заболеваний, таких как рак легких и туберкулез [23].

Ранняя диагностика заболеваний для успешного лечения и минимизации риска тяжелых последствий всегда была ключевой для медицинской практики в России. Предупреждение болезней часто оказывается более простой задачей, чем их лечение, и терапия на начальных этапах обычно бывает более результативной и экономически оправданной, чем на поздних стадиях. С развитием медицинских технологий и доступом к современным образовательным ресурсам в России активно внедряются передовые методы диагностирования, включая низкодозовую спиральную КТ, которая является высокочувствительным и точным методом для обнаружения небольших участков в легких и других ранних проявлений заболеваний.

Современная медицина усиленно работает над созданием и применением программ скрининга, цель которых раннее выявление заболеваний, имеющих важное социальное значение. Это способствует укреплению профилактической медицины и уменьшению риска тяжелых медицинских случаев.

Программы раннего выявления рака легких, основанные на использовании низкодозовой спиральной компьютерной томографии, набирают популярность и становятся частью стандартной медицинской практики. Такие программы показывают обнадеживающие результаты в раннем обнаружении рака легких, что помогает значительно сокращать уровень летальности от этой болезни.

Профилактическое обследование представляет собой процедуру обнаружения заболеваний у лиц, которые еще не проявляют симптомов и, следовательно, не ищут медицинской помощи, — это скрининг. Подход является эффективным, если заболевание имеет серьезное социальное и медицинское значение. При проведении профилактических обследований применяются различные диагностические методы, позволяющие выявить болезнь на ранних этапах, когда лечение наиболее результативно и необходим доступный, безопасный и надежный диагностический тест, который не вызывает серьезных побочных эффектов и ошибок в диагностировании. Когда в ходе профилактического обследования выявляется заболевание, пациентам предоставляется возможность пройти дополнительную диагностику и получить

необходимое лечение. Важно также, чтобы расходы на проведение скрининга и последующее лечение были экономически обоснованными для государства или региона, то есть чтобы они были меньше, чем затраты на лечение пациентов, обратившихся за медицинской помощью уже с проявленными симптомами болезни [24].

Профилактическое обследование состоит из трех ключевых этапов:

- разработка нормативно-правовой базы, идентификация групп риска, информирование населения, планирование обследований. Осуществляется медицинским персоналом и общественными организациями;
- контроль специалистов, методология и технические характеристики оборудования;
- пациенты с выявленной патологией в специализированных учреждениях.

Радиологические исследования для выявления заболеваний на ранней стадии вызывают как поддержку, так и критику. Понятие "ранняя" или "своевременная" диагностика может варьироваться в зависимости от медицинской специализации. Например, термин "ранний рак легкого" может интерпретироваться по-разному в патологии, рентгенологии и онкологии. Важно также четко определить, какая именно форма заболевания будет изучаться в ходе скрининга, чтобы правильно построить программу и оценить ее результаты.

В двадцатом веке флюорография стала одним из ключевых рентгенологических методов скрининга, особенно важным для раннего выявления туберкулеза. Этот метод, который был разработан в конце 30-х годов, получил широкое распространение после второй мировой войны во многих странах, включая СССР, США, Японию и европейские государства. Флюорография оказалась экономически выгодной альтернативой перед ранее использовавшимися рентгеноскопией и рентгенографией, так как позволяла использовать менее затратные и более удобные в обращении фотопленки.

Флюорография оказалась ключевой в ограничении распространения туберкулеза, но в последующие десятилетия программы скрининга были

модифицированы, оставив флюорографические осмотры преимущественно для групп высокого риска. С 90-х годов прошлого века такие обследования начали переходить к цифровому формату.

В России с 50-х годов внедрялись национальные программы борьбы с туберкулезом, в том числе флюорографический скрининг [25]. Это позволило разработать эффективные методики проведения исследований и способствовало раннему выявлению заболеваний дыхательных путей.

На сегодняшний день флюорография продолжает быть главным инструментом для обнаружения скрытых патологий легких, включая туберкулез и онкологические заболевания. Тем не менее, эффективность таких исследований зависит от правильного выбора целевых групп, а также от усовершенствования организации скринингов.

Ключ к повышению результативности флюорографии лежит в анализе предыдущих рентгеновских снимков, что дает возможность отслеживания динамики изменений и раннего выявления заболеваний [25]. Похожесть признаков на начальных стадиях разных заболеваний делает сравнительный анализ текущих и прошлых снимков ценным инструментом дифференциальной диагностики.

Также важно обеспечить грамотную организацию дополнительного обследования пациентов с подозрениями на заболевания. Углубленное исследование, включая лучевые методы, инструментальные и лабораторные тесты, должно быть доступно и проводиться своевременно для возможности незамедлительного начала лечения после диагностики. Кроме того, важно обратить внимание на новые программы скрининга, использующие современные технологии лучевой диагностики для анализа состояния легких: ранняя диагностика рака легких с использованием низкодозовой спиральной компьютерной томографии, а также оценка изменений в легочной ткани с целью выявления начальных стадий заболеваний органов дыхания.

Программы скрининга на основе таких технологий способствуют раннему выявлению патологий легких и позволяют начать лечение на ранних стадиях заболевания, что значительно повышает шансы на успешное выздоровление.

Значимым аспектом скрининга является не только проведение диагностических тестов, но и организация обследования больших групп населения из групп риска в соответствии с установленными стандартами. Также важно обеспечить проведение уточняющего обследования для лиц, у которых была выявлена патология.

Одним из наиболее серьезных заболеваний в области медицины и общественного здравоохранения является рак легких. Он занимает лидирующую позицию в структуре онкологических заболеваний как в России, так и во многих других странах мира. Ежегодно больше 60 тысяч человек в России заболевают раком легких, и 70% случаев выявляются на поздних стадиях заболевания. Основным фактором риска развития рака легких является курение, которое связано с более чем 90% случаев у мужчин и 78% у женщин. Также к факторам риска относятся воздействие асбеста, радона, наследственная предрасположенность, хроническая обструктивная болезнь легких и пассивное курение.

Долгое время предполагалось, что рентгенография и флюорография легких могут быть эффективными методами для скрининга рака легких. Однако результаты рандомизированных клинических исследований, проведенных в 1970-х годах, показали, что рентгенографический скрининг не снижает смертность от рака легких. Несмотря на то, что рентгенография позволяет раньше выявлять изменения в легких, это не приводит к значительному снижению смертности в долгосрочной перспективе.

Таким образом, наряду с традиционными методами диагностики, современные технологии, включая низкодозовую спиральную КТ, играют ключевую роль в эффективной диагностике и контроле легочных заболеваний в России. Их внедрение и развитие направлены на повышение качества медицинской помощи и улучшение прогноза заболеваний органов дыхания.

В последние годы спиральная компьютерная томография (КТ) получила значительное внимание как метод скрининга рака легких. В когортных исследованиях было показано, что спиральная КТ обладает высокой чувствительностью и может обнаруживать опухоли на ранних стадиях, что позволяет увеличить долю операбельных случаев и повысить выживаемость пациентов [26].

До сих пор недостаточно данных, чтобы подтвердить, что скрининг с применением спиральной КТ снижает смертность от рака легких в обследуемых группах населения. Современные исследования, посвященные возможностям скрининга бронхогенного рака с использованием низкодозовой спиральной компьютерной томографии (КТ), вызывают большой интерес. Основное преимущество этой технологии заключается в значительно более высоком разрешении по сравнению с рентгенографией и флюорографией. Спиральная КТ позволяет выявлять одиночные очаги в легочной ткани размером более 2 мм, тогда как для рентгенографии или флюорографии этот размер должен превышать 10 мм. Современные протоколы сканирования также позволяют снизить дозу облучения при спиральной КТ до 2 мЗв и менее, что примерно в 1,5 раза больше, чем при обычной флюорографии.

Спиральная низкодозовая КТ позволяет обнаруживать очаги в легких у примерно 10–12% обследованных пациентов из группы риска, при этом у 0,5–2,0% пациентов эти очаги оказываются бронхогенным раком. Более 80% таких опухолей остаются незамеченными при рентгенографии и флюорографии.

В конце 2010 года исследователи Национального проекта по скринингу рака легких в США представили результаты первого рандомизированного многоцентрового исследования. В этом исследовании, в котором участвовали более 53 тысяч курильщиков и бывших курильщиков, сравнивались многослойная КТ и рентгенография легких в скрининге рака легких. Результаты показали, что в группе скрининга смертность от рака легких снизилась на 21% по сравнению с контрольной группой. Более того, смертность от неонкологических причин снизилась на 7% среди пациентов, которые прошли

скрининг. Эти данные стали первым достоверным доказательством эффективности скрининга рака легких с использованием КТ. Однако дальнейшие исследования необходимы для решения ряда вопросов, включая частоту проведения КТ, стоимость программ скрининга и возможность включения некурящих пациентов с высоким риском развития рака легких.

Таким образом, внедрение современных методов анализа легких в клинической практике в России позволяет существенно улучшить возможности ранней диагностики, повысить эффективность скрининга и снизить смертность от рака легких. Вместе с тем, необходимо продолжать исследования в этой области, чтобы более полно оценить потенциал современных методов и оптимизировать их использование для достижения наилучших результатов в борьбе с этим серьезным заболеванием.

1.2.2 Обзор подходов к регистрации данных при диагностике заболевания легких

Регистрация данных в диагностике заболеваний легких представляет собой важный этап, который включает в себя сбор, обработку и анализ различных видов медицинской информации. Эти данные могут включать рентгеновские снимки, компьютерную томографию (КТ), результаты лабораторных тестов и другие диагностические методы. В этой части работы рассматриваются основные подходы к регистрации данных, используемые для диагностики заболеваний легких.

Традиционные методы регистрации данных включают ручной ввод информации и использование бумажных медицинских карт. Несмотря на свою надежность, эти методы имеют ряд недостатков, таких как высокая вероятность ошибок, трудоемкость и затраты времени на обработку информации. Медицинские работники записывают результаты обследований и диагнозы вручную в бумажные медицинские карты. Стандартизированные формы и шаблоны используются для систематизации данных. Цифровизация медицинских данных значительно улучшила процесс регистрации и анализа информации. В современных медицинских учреждениях используются

различные системы электронных медицинских записей (ЭМЗ), которые автоматизируют процесс сбора и хранения данных. Основные цифровые методы включают:

Электронные медицинские записи (ЭМЗ): Цифровые платформы для хранения медицинской информации, которые обеспечивают доступ к данным в реальном времени и улучшенную совместимость между различными отделами и учреждениями.

Системы управления изображениями (PACS): Специальные системы для хранения, передачи и анализа медицинских изображений, таких как рентгеновские снимки и КТ. Современные технологии позволяют автоматизировать процесс регистрации данных, что снижает вероятность ошибок и повышает эффективность диагностики. Основные подходы включают:

Машинное обучение и искусственный интеллект: Использование алгоритмов машинного обучения для автоматического анализа медицинских изображений и других данных. Это включает в себя обработку и классификацию изображений, выявление аномалий и прогнозирование заболеваний. Также присутствует подключение медицинских устройств к интернету для автоматического сбора и передачи данных. Это может включать в себя носимые устройства для мониторинга состояния пациента и сенсоры для регистрации жизненно важных показателей. Гибридные методы объединяют традиционные и цифровые подходы для обеспечения более полной и точной регистрации данных. Основные элементы гибридных методов включают:

Комбинирование автоматизированных систем с ручным вводом данных и использование автоматизированных систем для анализа данных и ручного ввода для подтверждения и корректировки информации. Современные методы регистрации данных имеют ряд преимуществ по сравнению с традиционными подходами: повышенная точность и снижение числа ошибок автоматизации процессов позволяет уменьшить вероятность человеческих ошибок, цифровые системы обеспечивают быстрый доступ к данным и информации в реальном времени, что ускоряет процесс диагностики и лечения.

Совместимость и интеграция играют важную роль. Системы легко интегрируются с различными медицинскими платформами, что улучшает совместимость данных и сотрудничество между медицинскими учреждениями.

Тем не менее существуют и вызовы, связанные с внедрением современных методов регистрации данных: защита данных и конфиденциальность; обеспечение безопасности медицинских данных и защита конфиденциальности пациентов являются критически важными задачами; сложность внедрения и обучения новых технологий требует значительных ресурсов и времени на обучение персонала; цифровые системы уязвимы для технических сбоев и кибератак, что требует постоянного мониторинга и обновления систем безопасности.

Современные методы регистрации данных, включая цифровые и автоматизированные системы, предоставляют значительные преимущества по сравнению с традиционными подходами, хотя и требуют решения ряда вызовов, связанных с защитой данных и техническими сложностями. Внедрение гибридных методов и постоянное совершенствование технологий помогут обеспечить высокое качество медицинских услуг и улучшить результаты диагностики и лечения заболеваний легких.

1.3 Междисциплинарные исследования цифровых изображений, характеризующих состояния легких

1.3.1 Геометрическая обработка для анализа форм и структур на рентгеновских снимках

Все рентгеновские симптомы при заболеваниях органов дыхания делятся на рентгеноморфологические и рентгенофункциональные. Изучение рентгеноморфологической симптоматики заключается в анализе легочного рисунка и характеристике затемнений и просветлений, возникающих как при заболеваниях органов дыхания, так и других органов грудной полости, а также при заболеваниях самой грудной клетки.

Анализ легочного рисунка уже был описан на сайте, где представлена характеристика нормального легочного рисунка. Легочный рисунок — это

исключительно рентгенологическое определение структуры легочной ткани. Такое теневое изображение присуще только легочной воздушной паренхиме и никакой другой ткани. Оно отличается своей теневой специфичностью от изображения мягкотканного компонента других воздухосодержащих образований, не говоря уже о безвоздушных органах в системах.

Таким образом, рентгеноморфологические симптомы включают различные изменения в легочном рисунке, а также затемнения и просветления, которые могут быть связаны как с болезнями органов дыхания, так и с патологиями других органов грудной полости и самой грудной клетки.

Основой легочного рисунка, как уже отмечалось, является разветвленная легочная артерия на фоне воздухосодержащих альвеол. Межуточная соединительнотканная строма легкого, через которую проходят артериовенозная и капиллярная сети, также играет важную роль в формировании теневой структуры легочного рисунка. Стволовые тени от разветвлений легочной артерии в виде суживающихся полос не всегда видны во всех зонах легочных полей, однако сотовидная зернистая структура в виде одиночных или нескольких ячеек обычно выявляется там, где имеется альвеолярная воздушная паренхима легочной ткани, объединенная в дольки.

Наличие межальвеолярных, межацинозных и междольковых соединительнотканых перегородок является основой ячеисто-тканевой картины легких, которая иногда получает резкое рентгенологическое отображение при патологических процессах, протекающих в этой межуточной структуре. Анализ легочного рисунка и оценка рентгенограммы легких включают в себя методичное изучение всех рентгеновских симптомов, возникающих при заболеваниях органов дыхания. Эти симптомы подразделяются на рентгеноморфологические и рентгенофункциональные.

Изучение рентгеноморфологической симптоматики заключается в анализе легочного рисунка и характеристике затемнений и просветлений, возникающих при заболеваниях органов дыхания, других органов грудной полости и самой грудной клетки. Легочный рисунок представляет собой исключительно

рентгенологическое определение структуры легочной ткани. Такое теневое изображение имеет только легочная воздушная паренхима и никакая другая ткань. Она отличается своей теневой специфичностью от изображения мягкотканного компонента других воздухосодержащих образований, не говоря уже о безвоздушных органах.

Анализ легочного рисунка включает общий обзор, сравнение выраженности рисунка в левом и правом легочных полях и детальный анализ по дополнительным легочным полям с каждой стороны по общепринятому трехпольному разделению. Это необходимо, поскольку легочный рисунок в каждом поле имеет свои особенности. Во внутренних зонах всех полей крупные стволы легочной артерии направлены вверх в верхнем и среднем полях, и вниз в нижнем поле.

В срединных и внешних зонах среднего поля сосудистые тени имеют горизонтальное направление, в нижнем поле направлены косо вниз, а в верхнем - косо вверх. Для более удобного подсчета элементов легочного рисунка и их количества на определенную площадь легкого целесообразно использовать ромбоидальные области, образуемые пересечением передних и задних отделов ребер. Кроме верхушек, обычно четко видны шесть межреберных пространств, каждое из которых содержит в среднем три-четыре ромбоидальные области. В этих областях легко подсчитать количество сосудистых полосок, пересекающих рентгеновские лучи. В норме наиболее выражена сосудистая сеть в двух внутренних ромбоидах, которые практически совпадают с зонами легочных полей. В наружных ромбоидах сосудистые тени обычно не определяются.

Изменения легочного рисунка можно классифицировать как усиление, деформацию и ослабление. Усиление проявляется в увеличении количества и размера сосудистых теней. Деформация характеризуется изменением нормальной структуры легочного рисунка, что может проявляться в виде искривлений и неравномерного распределения теней. Ослабление легочного рисунка, наоборот, связано с уменьшением количества и интенсивности сосудистых теней. Эти изменения могут быть вызваны различными

патологическими процессами в легких, такими как воспаления, новообразования или фиброзные изменения.

Для всех аномалий и заболеваний легких, включая инфильтраты, кисты, эмфизему и другие, размеры могут быть определены путем измерения следующих параметров:

- длина как расстояние от одного конца аномалии до другого в направлении, которое параллельно оси снимка легких;
- ширина, что является расстоянием между двумя противоположными сторонами аномалии, измеренным перпендикулярно к ее длине;
- высота — это вертикальное расстояние от верхней до нижней границы аномалии. Она может быть измерена параллельно вертикальной оси снимка.

Измерение этих параметров позволяет получить трехмерное представление об аномалии и оценить ее объем. Например, для кисты можно измерить длину, ширину и высоту, а затем вычислить ее объем, используя формулу для объема прямоугольного параллелепипеда ($V = \text{Длина} \times \text{Ширина} \times \text{Высота}$). Это помогает характеризовать форму и размеры аномалии для дальнейшего анализа и диагностики.

При COVID-19 определение размера и формы пневмонических инфильтратов может быть разнообразным, но часто они имеют неровные контуры и неправильную форму. Инфильтраты при COVID-19 могут быть распределены диффузно по всему легочному полю или иметь особенности распределения в определенных областях. На рентгеновских снимках COVID-19 можно наблюдать увеличение зоны теней внутри легких, что отражает обострение воспалительного процесса.

Пневмония может иметь различные размеры и формы, от мелких фокусов до больших областей, занимающих значительную часть легочного поля. Она может быть заметна затемнена или как область с размытыми контурами и более плотной текстурой по сравнению с окружающими тканями. Может быть

локализована в одном или нескольких легочных долях, а также может быть диффузно распределена по всему легочному полю.

Бронхиальная астма в случае обострения может наблюдаться в виде увеличения размеров легких вследствие эмфизематозных изменений, а также утолщение стенок бронхов. Текстура легких может быть более воздушной вследствие повышенной аэрации и раздутия альвеол. Возможно появление эмфизематозных изменений в верхних и средних долях легких, а также изменений в структуре бронхов, особенно при хроническом течении заболевания.

Эти характеристики помогают врачам различать и диагностировать различные заболевания легких на рентгеновских снимках, что важно для определения оптимального лечения и управления пациентом.

1.3.2 Статистические методы аномалий и паттернов

Легкие являются органом дыхания, который играет центральную роль в процессе вдыхания и выдыхания воздуха. Заболевания легких могут быть вызваны различными факторами, включая инфекции, хронические заболевания, такие как астма и хроническая обструктивная болезнь легких (ХОБЛ), и вредные привычки, такие как курение.

Важность заболеваемости легких для общественного здоровья не может быть недооценена. Это не только угрожает здоровью отдельных индивидуумов, но и может привести к значительным экономическим потерям из-за увеличения затрат на медицинскую помощь и реабилитацию. Кроме того, заболевания легких могут ухудшить качество жизни пациентов, ограничивая их способность выполнять повседневные задачи и участвовать в социальной жизни. Современные методы обработки изображений, в том числе методы Z-оценки, гауссовской смеси, локального бинарного шаблона, адаптивного порога и обнаружения краев, становятся незаменимыми инструментами для автоматизации этого процесса анализа. В этом обзоре мы рассмотрим каждый из этих методов и их применение в контексте анализа снимков легких.

Метод Z-оценки представляет собой мощный инструмент статистического анализа, который может быть эффективно применен для обнаружения аномалий на изображениях снимков легких. Он основан на понятии стандартного отклонения и среднего значения. Он позволяет оценить, насколько наблюдаемое значение отклоняется от среднего значения в единицах стандартного отклонения. Это позволяет идентифицировать значения, которые сильно отличаются от ожидаемого, что может указывать на наличие аномалий или патологических изменений.

Применение метода в анализе снимков легких для каждого пикселя изображения вычисляются Z-оценки. Это делается путем вычитания среднего значения интенсивности пикселя из его наблюдаемого значения, а затем деления на стандартное отклонение. Формула вычисления Z-оценки выглядит следующим образом (1.1).

$$Z = \frac{X - \mu}{\sigma} \quad (1.1)$$

где X - наблюдаемое значение интенсивности пикселя, μ - среднее значение интенсивности пикселя на всем изображении, σ - стандартное отклонение интенсивности пикселя на всем изображении.

После вычисления Z-оценок устанавливается пороговое значение. Пиксели, у которых Z-оценка превышает этот порог, считаются аномальными. Пиксели, для которых Z-оценка превышает порог, могут быть помечены как потенциальные аномалии. Это позволяет выделить области на изображении, которые значительно отличаются от общего паттерна интенсивности пикселей и могут указывать на наличие патологий или аномалий.

Преимущества метода Z-оценки:

- простота применения и интерпретации;
- позволяет обнаружить аномальные области без необходимости предварительного обучения модели;
- эффективен при выявлении явных аномалий в данных.

Ограничения метода Z-оценки в неэффективности при обнаружении сложных или скрытых аномалий. Чувствительность к выбору порогового значения, которое может потребовать тщательной настройки.

В целом, метод Z-оценки представляет собой полезный инструмент для первичного обнаружения аномалий на снимках легких в MATLAB. Он может быть эффективно использован в сочетании с другими методами для создания более точной системы обнаружения аномалий.

Метод гауссовской смеси (Gaussian Mixture Model, GMM): моделирует распределение данных как смесь нескольких гауссовских распределений. Это означает, что данные представляют собой смесь нескольких подгрупп, каждая из которых может быть описана гауссовским распределением. В контексте анализа изображений, каждый пиксель может быть рассмотрен как случайная переменная, и GMM используется для моделирования распределения интенсивности пикселей.

Применение метода в анализе снимков легких: моделирование данных: сначала данные, представляющие интенсивность пикселей на изображении легких, моделируются как смесь нескольких гауссовских распределений. Количество компонентов GMM (гауссиан) может быть определено заранее или настроено автоматически. Для каждой компоненты GMM оцениваются параметры, включая среднее значение, матрицу ковариации и весовой коэффициент. Это делается с использованием методов максимального правдоподобия или EM-алгоритма.

Классификация пикселей параметров GMM где каждый пиксель классифицируется как принадлежащий к одной из компонент. Пиксели, которые не соответствуют ни одной из компонент, могут быть рассмотрены как аномальные. Пометка аномальных областей, которые не соответствуют ни одной компоненте GMM, могут быть помечены как потенциальные аномалии. Это позволяет выделить области на изображении, которые значительно отличаются от общего распределения интенсивности пикселей и могут указывать на наличие патологий или аномалий.

Преимуществом метода гауссовской смеси является моделирование сложных распределений данных, которые не могут быть описаны одним гауссовским распределением, что позволяет обнаруживать скрытые структуры в данных, которые могут быть скрыты при использовании более простых методов.

Эффективен при обнаружении аномалий в данных, которые не соответствуют общему паттерну. Однако он не лишен ограничений, а именно он требует настройки количества компонентов GMM, что может быть сложной задачей. Чувствителен к начальным значениям параметров, и не всегда может гарантировать оптимальные результаты без дополнительных настроек.

Использование метода гауссовской смеси в анализе снимков легких в MATLAB может быть эффективным способом выделения аномальных областей и выявления патологий или изменений.

Метод локального бинарного шаблона (Local Binary Patterns, LBP) — это метод описания текстурных характеристик изображений путем анализа локальных шаблонов интенсивности пикселей. Он основан на представлении каждого пикселя в изображении как бинарного числа, зависящего от интенсивностей этого пикселя и его окрестностей. Пиксели внутри локальной окрестности анализируются, и для каждого пикселя вычисляется его LBP-код.

Извлечение текстурных признаков в контексте снимков легких, может быть использован для извлечения текстурных признаков из изображений. Каждый пиксель в изображении заменяется его LBP-кодом, который представляет локальный текстурный шаблон вокруг этого пикселя.

Анализ изменений в текстурных паттернах: после извлечения LBP-признаков можно проанализировать изменения в текстурных паттернах на изображении. Аномальные области, которые существенно отличаются по текстурным характеристикам от окружающих участков, могут быть обнаружены путем сравнения LBP-признаков различных областей изображения. Области, для которых существенно отличаются текстурные характеристики, могут быть рассмотрены как потенциальные аномалии. Например, изменения текстуры,

вызванные наличием опухоли или другой патологии в легких, могут быть выделены с использованием LBP.

Преимуществами метода локального бинарного шаблона являются: эффективно описывает текстурные характеристики изображений, не требует большого количества вычислительных ресурсов для вычисления, может быть эффективным при обнаружении изменений в текстуре изображений, что полезно для выявления аномалий. Он так же не лишен ограничений, а именно чувствителен к изменениям масштаба и освещения. Требуется настройки параметров, таких как размер окна и радиус окрестности.

В целом, метод локального бинарного шаблона представляет собой эффективный инструмент для анализа текстурных характеристик снимков легких и выявления аномалий, таких как патологии или изменения.

Метод адаптивного порога (Adaptive Thresholding) применяет пороговую обработку к изображениям с учетом локальных характеристик интенсивности пикселей. В отличие от глобального порога, который применяется ко всему изображению, адаптивный порог рассматривает окрестность каждого пикселя и определяет порог локально.

Применение метода в анализе снимков легких в области выделения аномальных областей в контексте снимков легких, адаптивный пороговый метод может быть использован для выделения аномальных областей, которые значительно отличаются по интенсивности от окружающих участков. Поскольку интенсивность пикселей может сильно варьироваться в различных областях легких из-за наличия патологий или других аномалий, адаптивный порог может быть эффективным способом выделения потенциальных аномалий. Адаптивный пороговый метод учитывает локальные характеристики интенсивности пикселей, что позволяет более точно определить порог для каждой области изображения. Это особенно важно при анализе снимков легких, где могут быть различные уровни интенсивности в разных областях изображения.

Обнаружение аномалий, которые сильно отличаются по интенсивности от окружающих участков, могут быть обнаружены путем применения адаптивного

порога к изображению. Это позволяет выделить области, которые могут указывать на наличие патологий или других аномалий в легких.

Преимуществами адаптивного порога учитываются локальные характеристики интенсивности пикселей это позволяет более точно выделить аномальные области на изображении. Эффективен при анализе изображений с большими различиями в интенсивности в различных областях. Ограничения метода адаптивного порога требует настройки параметров, таких как размер окна или метод определения порога. Может быть чувствителен к шуму или артефактам на изображении.

В целом, метод адаптивного порога представляет собой эффективный инструмент для выделения аномальных областей на снимках легких и может быть использован в сочетании с другими методами анализа для создания более точной системы обнаружения аномалий.

Метод выявления контуров (Edge Detection — это процесс обработки изображений, который позволяет определить границы объектов. Этот метод основывается на идентификации значительных изменений в яркости пикселей на изображении. Он базируется на предположении, что границы объектов обычно соответствуют местам, где интенсивность пикселей значительно изменяется. Применение метода в анализе снимков легких в контексте снимков легких, метод обнаружения краев может помочь выделить аномальные структуры или изменения внутри легких, такие как опухоли или жидкость.

Поскольку аномалии могут привести к резким изменениям интенсивности пикселей, обнаружение краев может быть эффективным методом для их выявления. Кроме того, обнаружение краев может помочь в анализе текстурных различий на изображении легких. Различия в текстуре могут быть индикаторами патологических изменений или аномалий. Обнаружение краев также может использоваться для улучшения визуализации структур на снимках легких. Это может помочь врачам и исследователям лучше понять форму и структуру легких и выявить любые аномалии или изменения.

Преимущества метода обнаружения краев:

- эффективно выделяет границы объектов на изображении;
- может помочь в выявлении аномальных структур или изменений;
- прост в реализации и применении;
- ограничения метода обнаружения краев.

Может быть чувствителен к шуму на изображении, что может привести к ложным обнаружениям краев. Требуется настройка параметров для достижения оптимальных результатов в различных условиях. В целом, метод обнаружения краев представляет собой важный инструмент в анализе снимков легких, который может помочь выявить аномалии и изменения, способствуя более точному диагнозу и лечению.

Анализ снимков легких с использованием методов обработки изображений является важным инструментом для диагностики различных патологий и заболеваний. От метода Z-оценки, использующего статистические подходы, до обнаружения краев, который выделяет границы объектов на изображении, каждый из этих методов представляет собой ценный инструмент для выявления аномалий и паттернов на снимках легких. Использование этих методов в сочетании с медицинскими знаниями и клиническим опытом способствует более точной диагностике и лечению пациентов, улучшая результаты в медицинской практике.

1.3.3 Применение алгоритмов машинного обучения и глубокого обучения нейросетей

Современный мир нейросетевых технологий характеризуется впечатляющим разнообразием архитектур. В основном, эти архитектуры могут быть разделены на две большие категории:

1. Нейросети прямого распространения, которые обрабатывают информацию в одном направлении, от входа к выходу без циклических маршрутов.

2. Рекуррентные нейросети, содержащие обратные связи, позволяющие информации повторно входить в сеть, что придает им динамические свойства.

Визуальное представление этих классов архитектур нейросетей можно увидеть на рисунке 1.1.

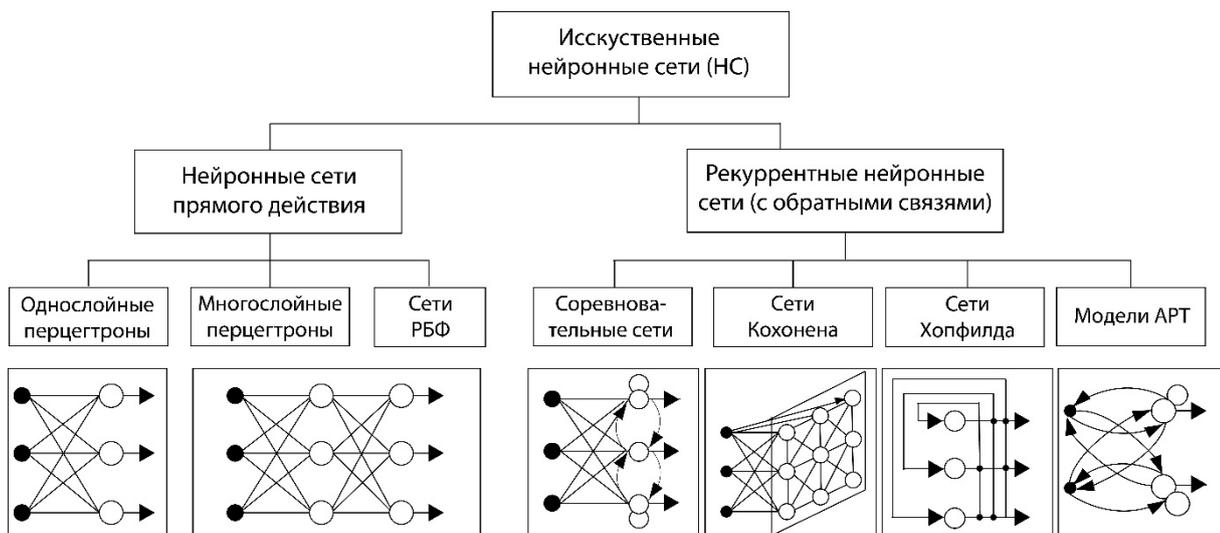


Рисунок 1.1 – Виды нейросетей.

Базовой структурой нейронных сетей, чаще всего используемой в сочетании с методом обратного распространения ошибки, является многоуровневая фидфорвардная сеть. Она представляет собой модель, где элементарная ячейка – нейрон – имеет множество входов R , каждый из которых умножается на соответствующий вес w . Общий взвешенный сигнал, собранный со всех входов, суммируется и передается в функцию активации (или передачи) f . Для формирования выходного сигнала нейроны могут использовать различные дифференцируемые функции передачи f , такие как tansig (гиперболический тангенс), logsig (логистическая сигмоидная) или purelin (линейная функция). Детальное представление этого процесса иллюстрируется на рисунке 1.2.

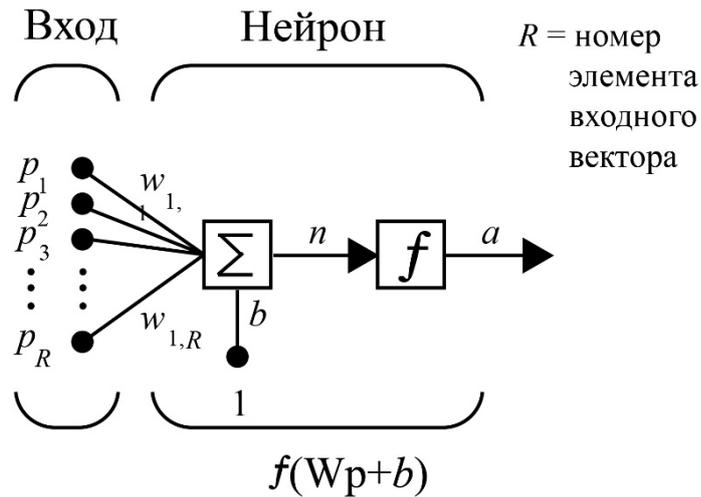


Рисунок 1.2 – Модель (tansig, logsig, purelin) элементарного нейрона

Многослойные нейронные сети часто применяют логарифмическую сигмоидную функцию передачи (logsig), которая преобразует входной сигнал в выходной в диапазоне от 0 до 1 для любых входных значений от минус бесконечности до плюс бесконечности. Альтернативной функцией является тангенциально-сигмоидная функция передачи (tansig), которая также ограничивает выходной сигнал, но уже в диапазоне от -1 до 1.

В сетях с методом обратного распространения ошибки иногда используется и линейная функция передачи (purelin), благодаря которой выходные значения сети не ограничены и могут принимать любые значения. Важным аспектом при использовании backpropagation является возможность вычисления производных функций активации, что необходимо для корректировки весов. Для функций tansig, logsig и purelin существуют соответствующие производные функции: dtansig, dlogsig и dpurelin. Для получения производной функции от функции передачи можно использовать команду с добавлением 'deriv', например, tansig('deriv') вернет dtansig.

Возможности для выбора функций активации в нейронных сетях велики, но logsig, tansig и purelin являются наиболее распространенными благодаря их вычислительной эффективности и полезным математическим характеристикам. На представленном рисунке иллюстрируется нейронная сеть с одним слоем, состоящим из S нейронов, каждый из которых принимает R входных сигналов.

Слева на рисунке показаны детали структуры сети, в то время как справа находится схематическое изображение этой структуры.

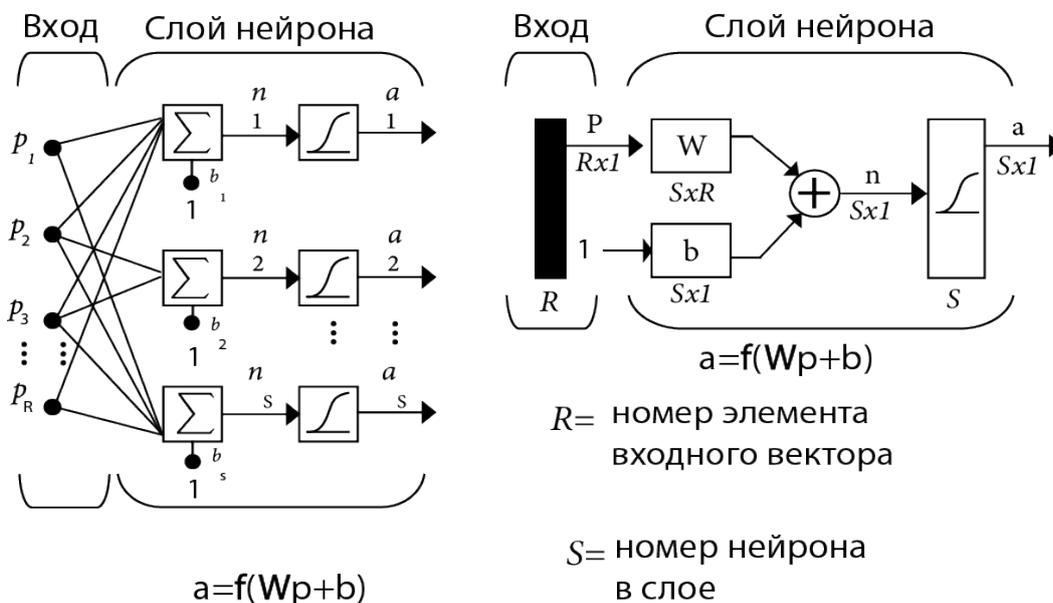
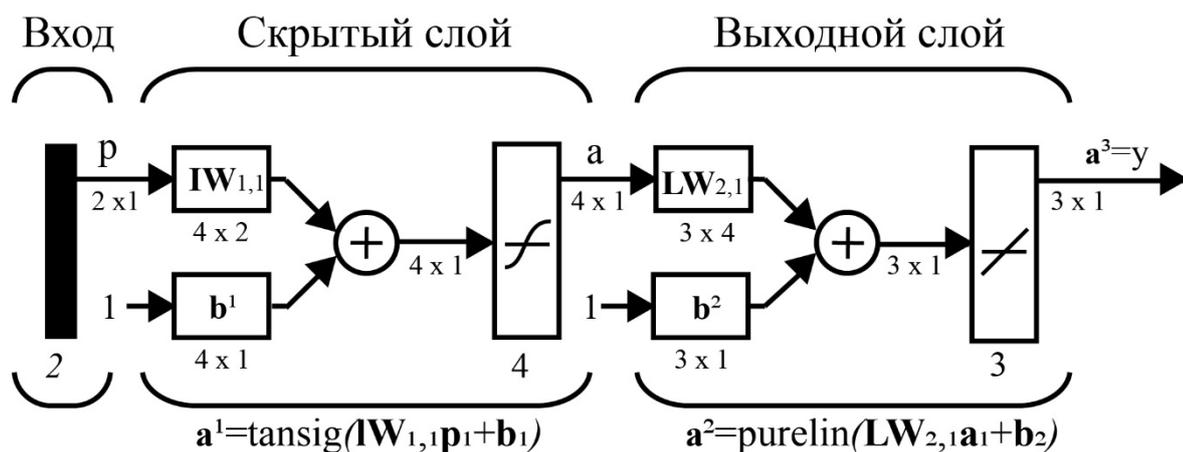


Рисунок 1.3 – Сеть с одиночным слоем S нейронов

Сети Feedforward зачастую включают в себя один или несколько скрытых слоев с сигмоидными нейронами и завершаются слоем выходных линейных нейронов. Многослойная архитектура с применением нелинейных функций активации позволяет моделировать как нелинейные, так и линейные взаимосвязи между входными и выходными векторами данных. Линейный выходной слой обеспечивает способность сети генерировать выходные данные, превышающие диапазон от -1 до +1.

В случае необходимости ограничения выходных данных в пределах диапазона от 0 до 1 следует использовать сигмоидную функцию передачи типа *logsig* на выходном уровне. В многослойных сетях индекс слоя используется для обозначения весов в матрицах, связывающих слои между собой. Пример такой архитектуры с использованием функций активации *tansig* на скрытом слое и *purelin* на выходном слое можно увидеть на иллюстрации под номером 1.4.



1.4 – Сеть с двумя нейронами

Эта сеть может функционировать как универсальный аппроксиматор функций. Способна с необходимой точностью аппроксимировать любую функцию с конечным числом разрывов, при условии достаточного количества нейронов на скрытом уровне. Создание сети осуществляется с помощью функции `newff`. Первым шагом при работе с `feedforward` сетью является создание сетевого объекта. Функция `newff` инициализирует `feedforward` сеть, требуя для этого четыре аргумента и возвращая сетевой объект. Первый аргумент – двумерная матрица минимальных и максимальных значений для каждого из R элементов входного вектора. Второй аргумент – массив, содержащий размеры каждого слоя. Третий аргумент – массив `cell`, включающий названия функций передачи для каждого слоя. Последний аргумент определяет функцию обучения. К примеру, команда ниже создает сеть с двумя слоями: один входной вектор с двумя элементами, диапазон первого элемента от -1 до 2, второго – от 0 до 5. В первом слое размещены три нейрона, в выходном – один.

Основные шаги реализации нейронной сети для выполнения задачи следующие:

- подготовка данных для обучения сети;
- создание сети;
- обучение сети;
- тестирование сети;
- использование сети для решения поставленной задачи.

При подготовке данных нужно определить размерности входных P и выходных T последовательностей. Желательно, чтобы входные и выходные данные были в диапазоне от -1 до $+1$, но это не обязательно, так как существуют методы нормализации.

Выбор структуры сети зависит от опыта разработчика, включая:

- количество слоев сети;
- число нейронов в слое;
- размерность входного и выходного слоев, соответствующая размерности входных и выходных векторов;
- тип функции активации на каждом слое;
- алгоритм обучения, например, `trainlm`.

Необходимо также установить параметры обучения, критерии окончания обучения и максимальное количество эпох. Процесс обучения часто визуализируется графиком, где отображается зависимость ошибки от эпохи обучения. Для оценки надежности работы сети используются результаты регрессионного анализа, сравнивая эталонные значения с результатами, полученными сетью на тестовых данных.

2 МЕТОДЫ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА РАСТРОВЫХ ИЗОБРАЖЕНИЙ

2.1 Методы фрактального и мультифрактального анализа

Фракталы и мультифракталы применяются для описания самоподобных характеристик, наблюдаемых в различных физических явлениях. Фракталы представляют собой геометрические структуры с крайне сложными и изрезанными формами, которые проявляют повторяемость на различных масштабах, как показано на рисунке 2.1. Эта повторяемость может быть точной, что характерно для регулярных фракталов, либо включать элементы случайности, что характерно для случайных фракталов.

В случайных фракталах структура на микроуровне не дублирует весь объект, однако статистические свойства этих фрактальных частей совпадают, подтверждая самоподобие при статистическом усреднении по множественным независимым случаям. Для описания фрактальных структур часто достаточно одного параметра, такого как размерность Хаусдорфа или коэффициент масштабирования, который отражает сохранение геометрии или статистики при изменении масштаба. Однако в таких областях, как физика, химия и биология, встречаются явления, для полного описания которых требуется более сложная мультифрактальная структура с несколькими показателями масштабирования.

Эти сложные структуры, известные как мультифракталы, особенно важны, поскольку они чаще встречаются в природе, в отличие от более простых самоподобных структур, которые являются идеализированными. Мультифрактальный подход предполагает, что объект можно разделить на множество фрагментов, каждый из которых обладает своими уникальными самоподобными свойствами.

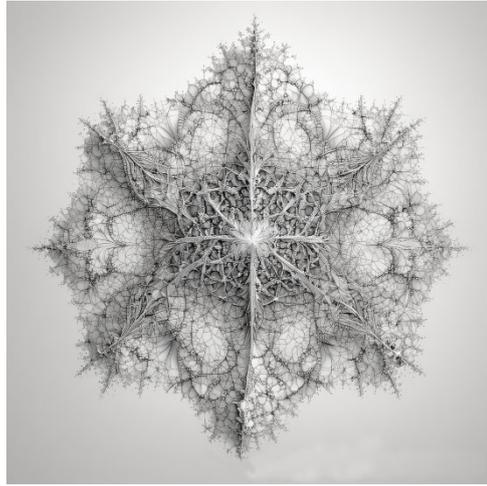


Рисунок 2.1. Пример фрактала

Первоначально предложенный для статистического анализа особенностей масштабирования сингулярных мер этот подход успешно применяется в различных научных областях. Он используется для изучения агрегационных свойств клеточных элементов крови в биологии, диффузионного роста кластеров, характеристики разрушения материалов в физике металлов, теории развитой гидродинамической турбулентности, исследования несоразмерных структур и квазикристаллов в физике твердого тела, анализа структуры молекул ДНК, одномерных случайных блужданий и броуновского движения, а также для описания инвариантной вероятностной меры странных аттракторов. Множество природных объектов можно отнести к категории "мультифракталов", и сложно найти научную область, где бы они не встречались.

Многие регистрируемые сигналы в натуральных экспериментах являются мультифракталами. Для решения ряда практических задач важно наличие строгого математического подхода к анализу сложных структур процессов различной природы. Монофрактальные сигналы, такие как $1/f$ -шум или процесс Винера, однородны и имеют постоянные характеристики масштабирования. Их частотная зависимость в спектре описывается формулой $S(f) \sim f^{-\beta}$ и остается неизменной в широком частотном диапазоне. Мультифрактальные процессы - напротив, имеют участки с различными локальными свойствами масштабирования, что требует более сложного количественного описания.

Их спектр не может быть описан степенным законом с единственным показателем β . Было предпринято несколько попыток расширить концепцию мультифракталов на случай функциональных зависимостей. Один из подходов основывается на методе структурных функций, который часто использовался для изучения сильно развитой турбулентности. В начале 90-х годов Мьюзи, Бакри и Арнеодо предложили метод "максимумов модулей вейвлет-преобразования" (ММВП), который обладает рядом преимуществ: анализирует широкий класс сингулярностей, включая производные сигналов, и обеспечивает меньшую погрешность вычисления характеристик масштабирования.

Метод ММВП стал одним из популярных инструментов анализа нестационарных данных. После публикации работы по мультифрактальному описанию сердечного ритма в журнале "Nature" в 1999 году и последующих исследований метод начал широко использоваться для обработки медико-биологических процессов, особенно в случаях, когда нестационарность ограничивает применение классических методов анализа. За последние годы наличие мультифрактальной структуры было обнаружено и охарактеризовано в динамике различных систем. Считается, что метод ММВП является мощным инструментом статистического описания неоднородных процессов и может существенно повлиять на развитие теории анализа структуры нестационарных сигналов.

Многие природные процессы относятся к классу "мультифракталов", что делает изучение этого явления интересным и с практической точки зрения. Исследование мультифрактальности и возможности её количественного описания представляет значительный интерес как для фундаментальных исследований, так и для прикладных задач. Методов обработки нестационарных данных немного: процессы изменяются на коротких временных интервалах, классические алгоритмы анализа могут давать ошибочные результаты.

Универсальные инструменты, независимые от стационарности, включают концепцию аналитического сигнала, метод анализа флуктуаций относительно тренда и вейвлет-анализ.

Мультифрактальный подход можно рассматривать как еще один важный инструмент в этом арсенале. Хотя он использует вейвлет-преобразование на промежуточных этапах, его нельзя рассматривать просто как часть вейвлет-анализа. Скорее, это сочетание теории вейвлетов и мультифракталов, аналогичной статистической термодинамики. Однако метод ММВП еще не получил широкого распространения среди исследователей, занимающихся обработкой экспериментальных данных. В данной работе изложены основы теории мультифрактального анализа сложных сигналов на основе вейвлет-преобразования, а также необходимые сведения для практического применения. Особое внимание уделено описанию новых возможностей анализа структуры сигналов и ограничений мультифрактального формализма.

2.2 Методы, основанные на вейвлет-преобразованиях

История анализа Фурье начинается с ряда Фурье, названного в честь французского математика Жана-Батиста Жозефа Фурье (1768–1830), который сделал значительный вклад в исследование тригонометрических рядов, продолжив работы Леонарда Эйлера, Жана Лерона д'Аламбера и Даниила Бернулли. Фурье разработал этот ряд для решения уравнений теплопроводности в металлических пластинах. Он представил свои первоначальные результаты в труде «Воспоминания о распространении тепла в твердых телах», а затем опубликовал их в «Аналитической теории тепла» (*Théorie analytique de la chaleur*) в 1822 году. Анализ Фурье возник при изучении свойств рядов Фурье, и назван в честь Жозефа Фурье, который показал, что представление функции в виде суммы тригонометрических функций значительно упрощает изучение процесса теплообмена. Конец прошлого века подарил успешное развитие направления теории и техники по обработке различных сигналов.

Примером хорошо спроектированного математического инструмента является анализ Фурье, который занимает одно из ключевых мест в математическом анализе и его применениях. Преобразование и ряды Фурье обладают фундаментальным значением благодаря своей простоте и ортогональности, основанной на функциях $\sin x$ и $\cos x$. Теория вейвлет-анализа

возникла из необходимости обрабатывать большие объемы данных, где традиционные методы преобразования Фурье показали свои ограничения.

Например, вейвлет-преобразование позволяет анализировать свойства сигнала как в временной, так и в частотной области, что невозможно с помощью преобразования Фурье. Развитие вычислительной техники также сыграло значительную роль, позволив численно решать задачи, которые ранее были недоступны. Огромный вклад в развитие и изучение теории вейвлетов внесли такие ученые, как Гроссман (A. Grossmann), Добеши (I. Dobechie), Малл (S. Mallat), Мейер (Y. Meyer), Морле (J. Morlet), Фарж (M. Farge), Чуи (K. Chui) и др.

Введение термина "вейвлет" произошло благодаря статье, опубликованной J. Morlet и A. Grossman в 1984 году. В то время они исследовали сейсмические сигналы с использованием базисных функций, которые они называли вейвлетами. Эта работа стала отправной точкой для дальнейшего развития теории вейвлетов в последующее десятилетие. Значительный вклад в теорию внесли Гроссман, Гуппилауд и Морлет, которые заложили основы непрерывного вейвлет-преобразования (CWT). Жан Олаф-Стромберг сыграл важную роль в разработке дискретных вейвлетов, Ингрид Добеши разработала ортогональные вейвлеты в 1988 году, Натали Делпрат создала время-частотную интерпретацию CWT в 1991 году, а Ньюланд разработал гармоническое вейвлет-преобразование. Эти и многие другие исследования значительно продвинули теорию и применение вейвлетов. В современную эпоху мы имеем возможность глубже изучать и экспериментировать с программно-аналитическими расширениями вейвлетов.

Уже существуют специализированные пакеты для компьютерной математики, такие как Matlab, Mathematica, Mathcad и другие, которые активно применяются в различных областях науки и техники. Вейвлет-преобразования и вейвлетный анализ используются для множества задач: от распознавания образов и численного моделирования динамики сложных нелинейных процессов до анализа медицинских изображений, космических технологий, астрономии, геофизики, эффективного сжатия сигналов и передачи данных через каналы с ограниченной пропускной способностью.

Исследователи часто называют вейвлет-анализ "математическим микроскопом", который позволяет тщательно изучать внутренние структуры неоднородных сигналов и функций. Подобно анализу Фурье, вейвлет-анализ делится на два раздела: вейвлет-преобразование и вейвлет-ряды. Вейвлет-преобразование представляет собой свертку с учетом растяжения некоторой базисной функции (вейвлета), тогда как вейвлет-ряд выражается через эту функцию с помощью двоичных сжатий и целочисленных сдвигов. В отличие от анализа Фурье, вейвлет-преобразование тесно связано с вейвлет-рядом. Однако не стоит воспринимать вейвлет-методы как универсальное решение для всех задач.

Потенциал вейвлетов еще не полностью раскрыт, но это не означает, что они полностью заменят традиционные методы обработки и анализа информации, которые хорошо зарекомендовали себя временем. Тем не менее, они могут значительно расширить возможности информационных технологий в области обработки данных.

В математике преобразование Фурье (FT) представляет собой математическое преобразование, которое разлагает функцию, часто функцию времени или сигнал, на составляющие частоты, подобно тому, как музыкальный аккорд можно представить через громкость и частоты его нот. Преобразование Фурье включает как представление частотной области, так и математическую операцию, связывающую временную область с частотной. Преобразование Фурье функции времени дает комплексную функцию частоты, где величина (абсолютное значение) представляет количество этой частоты в исходной функции, а аргумент - фазовый сдвиг основной синусоиды на данной частоте.

Преобразование Фурье не ограничивается временными функциями, хотя исходную функцию часто называют временной областью. Существует также обратное преобразование Фурье, которое позволяет математически восстановить исходную функцию из ее представления в частотной области, что подтверждается теоремой об обращении Фурье (2.1).

Преобразование функции Фурье вещественной переменной является интегральным и задаётся следующей формулой:

$$f(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(x) e^{-ix\omega} dx \quad (2.1)$$

Сейчас преобразование Фурье дает информацию только про частоту, которая присутствует в сигнале и не дает никакой информации про то, в какой промежуток времени эта частота присутствует в сигнале. Метод Фурье отлично подходит для анализа частотных составляющих сигнала, но при этом не предоставляет информацию о временном расположении этих частот. В различных переводах зарубежных статей на русский язык встречаются еще термины: «всплеск», «всплесковая функция», «маловолновая функция», «волночка» и др.

Вейвлет-анализ включает в себя два основных этапа: вейвлет-преобразование и последующий анализ результатов этого преобразования. Такое разделение объясняется несколькими причинами. Во-первых, вейвлет-преобразование часто используется самостоятельно, без последующего анализа, например, для сжатия изображений или видеоданных. Во-вторых, основной этап состоит из сложных математических вычислений, которые требуют значительного времени и выполняются автоматически, без вмешательства человека. В-третьих, результаты, полученные на первом этапе, могут быть подвергнуты анализу различными методами, что позволяет адаптировать их к конкретным задачам[28].

Под вейвлет-преобразованием функции $f(x) \in L^2(R)$ (дважды дифференцируемой на множестве действительных чисел) понимается скалярное произведение этой функции и базисных функций вида (2.2).

$$\psi_{a,b}(x) = a^{\frac{1}{2}} \psi\left(\frac{x-b}{a}\right) \quad (2.2)$$

Здесь a и b – параметры, причем a принимает положительные действительные значения, b – любые действительные значения. Иными словами,

вейвлет-преобразование – это разложение функции $f(x)$ по всем возможным сдвигам и сжатиям некоторой функции $\psi(x)$. Функцию $\psi(x)$ называют порождающим вейвлетом, материнской вейвлет-функцией или вейвлетом. Порождающий вейвлет $\psi(x)$ выбирается исследователем произвольно, исходя из цели исследования.

Примером порождающего вейвлета является «Мексиканская шляпа» (Mexican hat, МЕХИНАТ) – вторая производная от гауссианы (2.3).

$$\psi(x) = (x^2 - 1)e^{-\frac{x^2}{2}} \quad (2.3)$$

В случае, когда параметры a и b изменяются непрерывно, вейвлет-преобразование называют непрерывным (непрерывное вейвлет-преобразование, НВП). Получить функцию $W(a, b)$ в аналитическом виде можно только в том случае, если удастся взять интеграл в формуле (2.3). При вейвлет-анализе экспериментальных данных функция $f(x)$ представлена конечным набором чисел. Аналитический вид функции $\psi(x)$ выбирается из соображений удобства. Чаще всего экспериментальные данные представляют собой конечное дискретное однородное множество чисел. В этом случае интегрирование в (2.4) заменяется суммированием.

$$W(a, b) = e^{-\frac{1}{2}} \sum_{k=1}^p \int (x_i) \psi\left(\frac{x_k - b}{a}\right), k = 1 \dots p. \quad (2.4)$$

Преобразование (2.4) называется непрерывным вейвлет-преобразованием дискретных данных представленное на рисунке 2.2 функция W является непрерывной функцией своих аргументов a и b . Чаще всего выбирают конечный дискретный набор значений этих параметров $a \in (a_1, a_2, \dots, a_m)$; $b \in (b_1, b_2, \dots, b_m)$.

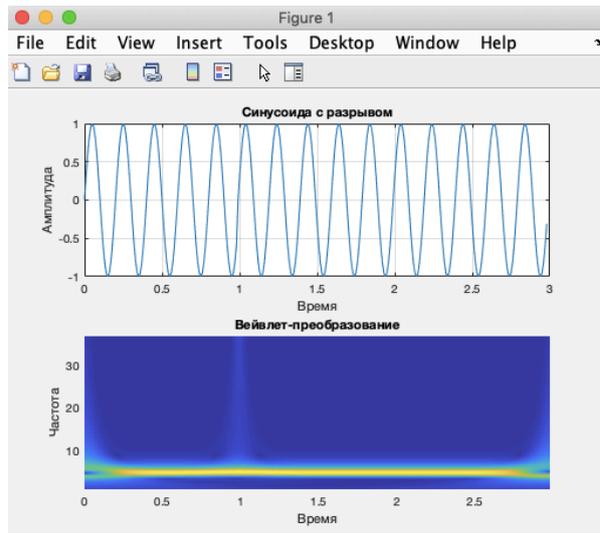


Рисунок 2.2 – Непрерывное преобразование

Тогда формула (2.5) принимает вид

$$W_{i,j} = a_i^{-\frac{1}{2}} \sum_{k=1}^p \int (x_i) \psi \left(\frac{x_k - b_j}{a_i} \right), \quad k = 1 \dots p, i = 1 \dots n, j = 1 \dots m. \quad (2.5)$$

Такое вейвлет-преобразование называют дискретным вейвлет-преобразованием дискретных данных. Результатом дискретного вейвлет-преобразования (5) является двумерный массив $W_{i,j}$, который удобно представить графически.

Функции двумерного вейвлет-преобразования по своему назначению аналогичны описанным выше функциям одномерного преобразования и идентифицируются цифрой 2 в конце одноименных функций одномерного преобразования, т. е.: `wavedec2`, `wavereg2`, `wrcoef2`, `upwlev2`, `appcoef2`, `detcoef2`, `urcoef2`, `dwt2`, `idwt2` пример представлен на рисунке 2.3.

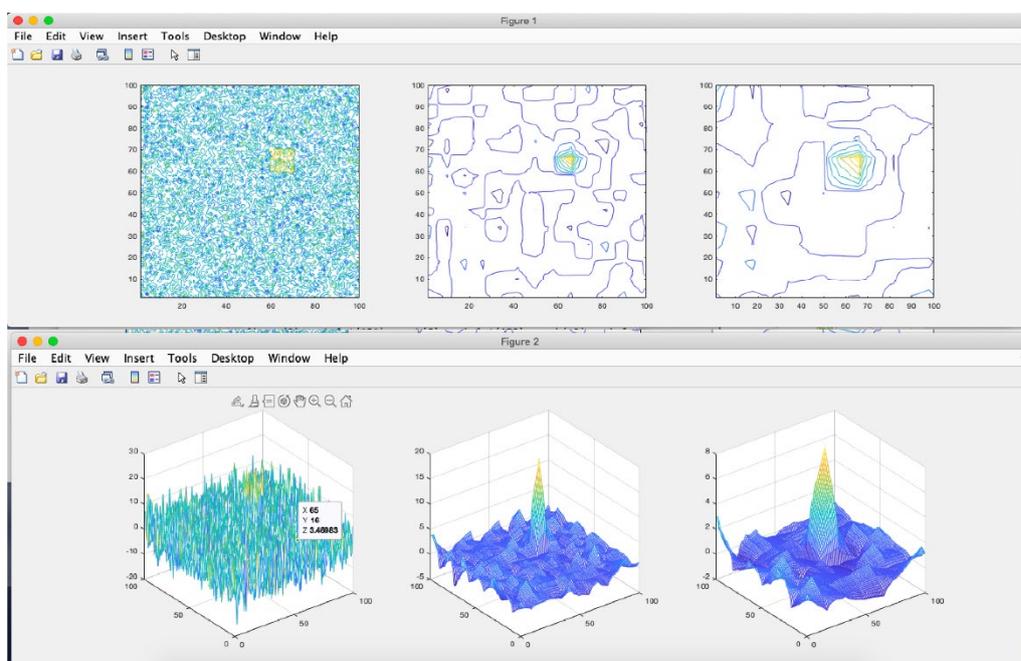


Рисунок 2.3 – Пример декомпозиции и аппроксимационной реконструкции двумерного сигнала

Модельные примеры демонстрируют успешное применение вейвлет-анализа для обработки экспериментальных данных. Данный метод эффективно выявляет периодичность в одномерных сигналах, позволяет определить период и продолжительность существования гармонических компонентов. Вейвлет-анализ также способен обнаруживать локальные особенности сигналов, такие как всплески и разрывы, что делает его незаменимым инструментом в изучении сложных временных рядов. Благодаря способности анализировать данные одновременно в частотной и временной областях, вейвлет-анализ предоставляет более полную картину динамических процессов, что особенно важно при исследовании нестационарных и нелинейных систем. Этот метод нашел широкое применение в различных научных и инженерных задачах, включая анализ биомедицинских сигналов, обработку изображений, диагностику технических систем и изучение природных явлений.

2.3 Цифровая обработка изображений в MATLAB

Интегрированные среды для моделирования и выполнения программ по цифровой обработке изображений и сигналов оснащены мощными инструментами для инженерных и научных расчетов, а также для визуализации

данных. Современные программные комплексы часто поддерживают визуальное программирование на основе блок-схем, что позволяет даже специалистам без навыков программирования разрабатывать эффективные программы. Одним из таких комплексов является Image Processing Toolbox, который входит в систему MATLAB и разработан компанией MathWorks. Этот набор инструментов предоставляет широкий спектр функций для обработки изображений, что делает его незаменимым для научных исследований и инженерных задач.

Этот пакет обладает мощными средствами для обработки изображений, имеет открытую архитектуру и позволяет организовывать взаимодействие с аппаратурой цифровой обработки сигналов, а также подключать стандартные драйвера. Система MATLAB и пакет прикладных программ Image Processing Toolbox (IPT) представляют собой отличный инструмент для разработки, исследования и моделирования методов и алгоритмов обработки изображений. При решении задач в этой области пакет IPT предоставляет два подхода.

Первый подход заключается в самостоятельной программной реализации методов и алгоритмов. Второй путь предполагает использование готовых функций, реализующих наиболее известные методы и алгоритмы обработки изображений. Оба подхода имеют свои достоинства. Однако для исследователей и разработчиков методов и алгоритмов обработки изображений предпочтительным является второй путь.

Это объясняется гибкостью таких программ и возможностью изменения всех параметров, что особенно важно при проведении исследований, разработке и определении параметров регуляризации. Перед использованием стандартных функций пакета IPT для решения конкретных задач, разработчик должен тщательно их изучить. Для этого необходимо точно знать, какой метод и с какими параметрами реализует та или иная функция.

Для анализа видеоданных как объектов исследования используется изображение. Рассмотрим особенности представления изображений в IPT. Изображения делятся на векторные и растровые. Векторные изображения описываются набором графических примитивов, а растровые изображения

представляют собой двумерный массив пикселей, каждый из которых содержит информацию о цвете. В цифровой обработке преимущественно используются растровые изображения, которые, в свою очередь, делятся на несколько типов: бинарные, полутоновые, палитровые и полноцветные.

Бинарные изображения состоят из элементов, которые могут принимать только два значения — 0 или 1. Такие изображения могут иметь различное происхождение, но чаще всего они получаются путем обработки полутоновых, палитровых или полноцветных изображений методами бинаризации с фиксированным или адаптивным порогом. Преимуществом бинарных изображений является их удобство для передачи данных. Полутоновые изображения состоят из элементов, которые могут принимать одно из значений интенсивности одного цвета. Этот тип изображений широко используется в различных исследованиях и имеет глубину цвета 8 бит на элемент изображения.

В палитровых изображениях значение пикселей является ссылкой на ячейку карты цветов (палитру), представляющей собой двумерный массив, в столбцах которого расположены интенсивности цветовых составляющих одного цвета. В отличие от палитровых изображений, элементы полноцветных изображений непосредственно хранят информацию о яркости цветовых составляющих.

Выбор типа изображения зависит от решаемой задачи и от того, насколько полно и без потерь нужная информация может быть представлена с заданной глубиной цвета. Следует также учитывать, что использование полноцветных изображений требует больших вычислительных затрат. В зависимости от типа изображения они по-разному представлены в различных форматах, что важно при создании программ в среде IPT.

При программной реализации рекомендуется избегать использования индексации строк с нулевой строки, так как MATLAB корректно воспринимает индексацию с первой строки. В дальнейшем, при рассмотрении методов обработки изображений, будем считать, что изображение представляется матрицей чисел размером $N \times M$, где значение каждого элемента соответствует

определенному уровню квантования его энергетической характеристики (яркости). Это так называемая пиксельная система координат, применяемая в большинстве функций пакета IPT.

Существует также пространственная система координат, в которой изображение представляется непрерывным числовым полем квадратов с единичной величиной, количество которых совпадает с числом пикселей. Значение интенсивности элемента в центре квадрата совпадает со значением соответствующего пикселя в пиксельной системе координат. При решении задач, связанных с измерениями реальных геометрических размеров объектов на изображении, удобно использовать пространственную систему координат, так как она позволяет учитывать разрешение системы (количество пикселей на метр).

Маска фильтра (или скользящее окно, или апертура) представляет собой матрицу определенного размера, накладываемую на изображение. Маска умножается на соответствующие элементы изображения с последующей обработкой результата. При перемещении маски к границе изображения возникает краевой эффект. Чтобы избежать этого эффекта, необходимо дополнять изображение элементами, симметричными относительно его краев, а не нулевыми элементами, как советует большинство книг по MATLAB.

Обработка изображений осуществляется рекурсивными и нерекурсивными методами. Рекурсивные методы используют результат обработки предыдущего пикселя, а нерекурсивные — нет. В большинстве случаев применяются нерекурсивные алгоритмы обработки изображений. Черно-белые (бинарные) изображения легче получать, хранить и обрабатывать по сравнению с изображениями с множеством уровней яркости.

Однако область применения бинарных изображений ограничена, так как они кодируют информацию только о силуэте объекта. В дальнейшем будут сформулированы условия для успешного использования методов обработки бинарных изображений с акцентом на простые геометрические характеристики изображений, такие как площадь объекта, его положение и ориентация. Эти

величины могут использоваться, например, при управлении механическим манипулятором при работе с деталями.

Поскольку изображения содержат большой объем информации, важным становится способ их представления. Геометрические характеристики можно извлечь из проекций бинарных изображений, которые легче хранить и обрабатывать. Также будут рассмотрены непрерывные бинарные изображения, характеристическая функция которых равна нулю или единице в каждой точке плоскости изображения. Это упрощает анализ, однако при использовании ЭВМ изображение необходимо разбить на дискретные элементы.

Начнем с рассмотрения случая, когда в поле зрения находится объект, а все остальное считается "фоном". Если объект заметно темнее (или светлее) фона, легко определить характеристическую функцию $b(x, y)$, которая равна нулю для всех точек изображения, соответствующих фону, и единице для точек на объекте рисунка 2.5 или наоборот.

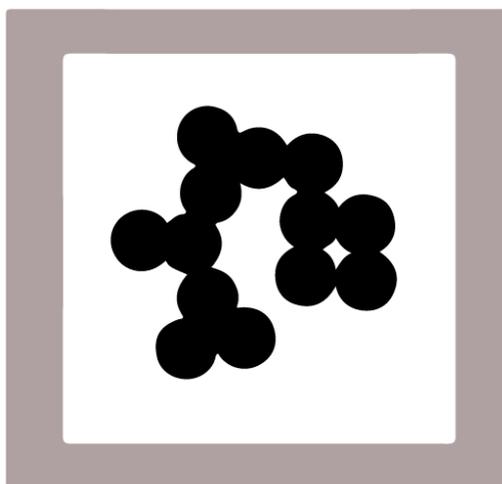


Рисунок 2.5 – Бинарное изображение, определяемое характеристической функцией $b(x, y)$, которая принимает значение “нуль” и “единица”.

Бинарные изображения часто создаются путем порогового разделения исходных изображений. Этого можно добиться также с помощью порогового разделения расстояния на изображении, полученном на основе измерений расстояний. Такой подход заключается в том, что функция, принимающая два значения (бинарное изображение), создается путем порогового разделения полутонового изображения. Суть этой операции в том, что характеристическая

функция принимает значение ноль в точках, где яркость превышает определенное пороговое значение, и значение один, где яркость меньше или равна порогу (или наоборот).

В некоторых случаях удобно рассматривать компоненты изображения, а также отверстия в них как множества точек. Это позволяет комбинировать изображения с помощью теоретико-множественных операций, таких как объединение и пересечение. В других ситуациях целесообразно применять булевы операции на уровне каждого пикселя. По сути, это два различных подхода для выполнения одних и тех же действий с изображениями.

Поскольку объем информации в бинарном изображении значительно меньше, чем в полутоновом изображении такого же размера, обработка, хранение и передача бинарных изображений гораздо проще. Однако часть информации теряется при переходе к бинарным изображениям, что ограничивает набор методов их обработки. На данный момент существует достаточно развитая теория, описывающая, что можно и чего нельзя делать с бинарными изображениями, чего, к сожалению, нельзя сказать о полутоновых изображениях.

С бинарными изображениями можно вычислить различные геометрические характеристики, такие как размер и положение объекта. Если в поле зрения находится несколько объектов, можно определить топологические характеристики совокупности объектов, например, разность между количеством объектов и числом отверстий (число Эйлера).

Обработка бинарных изображений хорошо изучена и может быть легко реализована аппаратно, однако необходимо учитывать некоторые ограничения. Например, для успешной обработки требуется высокий контраст между объектом и фоном. Кроме того, объект должен быть существенно двумерным, поскольку мы имеем дело только с его контуром или силуэтом. По этой информации сложно сделать выводы о форме или пространственном положении объекта.

Характеристическая функция $b(x, y)$ определена в каждой точке изображения. Такое изображение будем называть непрерывным. Позже мы рассмотрим дискретные бинарные изображения, получаемые путем подходящего разбиения поля изображения на элементы.

Простые геометрические характеристики

Допустим снова, что в поле зрения находится лишь один объект. Если известна характеристическая функция $b(x, y)$, то площадь объекта вычисляется следующим образом (2.6):

$$A = \iint_I b(x, y) dndy \quad (2.6)$$

Для определения площади объекта на изображении используется интегрирование по всему изображению I . Теперь перейдем к определению положения объекта на изображении. Поскольку объект обычно не представляет собой одну единственную точку, необходимо четко определить, что подразумевается под термином "положение". Чаще всего для этой цели выбирают геометрический центр объекта, как показано на рисунке. Этот геометрический центр (или центр масс) является характерной точкой объекта и может быть определен следующими математическими методами (рисунок 2.6).

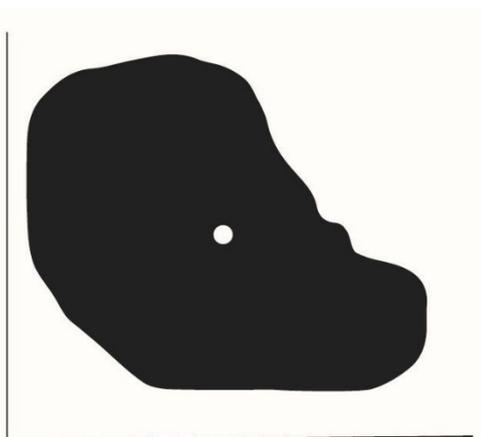


Рисунок 2.6 – Положение области на бинарном изображении, которое можно определить ее геометрическим центром. Последний представляет собой центр масс тонкого листа материала той же формы.

Геометрический центр — это центр масс однородной фигуры той же формы. В свою очередь центр масс определяется точкой, в которой можно сконцентрировать всю массу объекта без изменения его первого момента относительно любой оси. В двумерном случае первый момент относительно оси x рассчитывается по формуле (2.7) где (x,y) — координаты геометрического центра, а относительно оси y — по формуле (2.8)

$$x \iint_l b(x,y) dndy = \iint_l xb(x,y) dx dy \quad (2.7)$$

$$y \iint_l b(x,y) dx dy = \iint_l yb(x,y) dx dy \quad (2.8)$$

Интегралы в левой части приведенных соотношений — не что иное, как площадь A , о которой речь шла выше. Чтобы найти величины x и y , необходимо предположить, что величина A не равна нулю. Заметим попутно, что величина A представляет собой момент нулевого порядка функции $b(x,y)$.

Мы также стремимся определить, как ориентирован объект в поле зрения, то есть его ориентацию. Это задача несколько сложнее. Допустим, что объект немного вытянут вдоль определенной оси; в таком случае ориентацию этой оси можно принять за ориентацию объекта. Как же точно определить ось, вдоль которой вытянут объект? Обычно выбирают ось минимального второго момента. Это аналог двумерной оси наименьшей инерции. Для этого нужно найти прямую, для которой интеграл от квадратов расстояний до точек объекта минимален; этот интеграл выражается следующим образом (2.9) где γ — расстояние вдоль перпендикуляра от точки с координатами (x, y) до искомой прямой.

$$E \iint_l \gamma^2 b(x,y) dx dy \quad (2.9)$$

Для вычисления положения и ориентации объекта достаточно знать первые и вторые моменты (при этом остается двузначность в выборе направления на оси). Чтобы определить их значения, исходное изображение не требуется: достаточно иметь его проекции. Этот факт представляет интерес,

поскольку проекции описываются более компактно и позволяют использовать гораздо более быстрые алгоритмы.

Дискретные бинарные изображения до этого момента мы рассматривали непрерывные бинарные изображения, определенные во всех точках плоскости. Очевидно, что при переходе к дискретным изображениям интегралы преобразуются в суммы. Например, площадь вычисляется (в единицах площади элемента изображения) как сумма (2.10) где b_{ij} — значение бинарного изображения в точке, находящейся в i -й строке и j -м столбце. Здесь мы полагали, что поле изображения разбито на квадратную решетку с t столбцами и p строками.

$$A = \sum_{i=1}^n \sum_{j=1}^m b_{ij} \quad (2.10)$$

Часто изображение просматривается строка за строкой в той же самой последовательности, в какой телевизионный луч бежит по экрану (если не учитывать того, что четные строки считываются вслед за нечетными). Как только считано значение очередного элемента изображения, проверяем равенство $b_{ij} = 1$. Если оно выполняется, добавляем $1, i, j, i^2, ij$ и j^2 к накапливаемым значениям площади первых моментов и вторых моментов. По окончании цикла сканирования с помощью этих значений легко найти площадь, положение и ориентацию.

Существует несколько способов кодирования, позволяющих еще больше сжать информацию о бинарных изображениях. Одним из широко распространенных является кодирование с переменной длиной кодовой последовательности. Этот метод основан на том, что вдоль любой просматриваемой в данный момент строки обычно обнаруживаются длинные цепочки нулей и единиц. Поэтому вместо передачи отдельных битов информации мы можем посылать длины подобных цепочек. Код с переменной длиной есть просто [1,4,3,2,4].

Чтобы отметить начало каждой строки, вводится специальный признак. Также существует соглашение о том, с какого символа начинается строка (с нуля или единицы). Если строка начинается с противоположного символа, то первым символом кода ставится ноль. Кодирование с переменной длиной кодовой последовательности основывается на избыточности в одном измерении. Для сокращения затрат на передачу и хранение данных были предприняты попытки использовать пространственную взаимосвязь между элементами изображения в двух направлениях. Одной из наиболее успешных схем является схема, разработанная фирмой IBM, описанная в их отчете.

В Matlab также рассматривается один из видов кодирования, описанный в функции `BWPACK`. В настоящее время Matlab и пакет Image Processing Toolbox являются мощными инструментами для моделирования и исследования методов обработки изображений [29]. Они включают множество встроенных функций, реализующих распространенные методы обработки изображений. Рассмотрим основные возможности пакета Image Processing Toolbox. К наиболее распространенным функциям геометрических преобразований относятся кадрирование изображений (`imcrop`), изменение размеров (`imresize`) и поворот изображения (`imrotate`). Функция `imcrop` позволяет вырезать часть изображения с помощью мыши и поместить ее в новое окно просмотра (Приложение А).

Команда `imresize` активно применяется для коррекции габаритов визуального контента различного происхождения через определенные техники интерполяционного процесса. В рамках пакета Image Processing Toolbox также присутствует утилита `imrotate`, отвечающая за вращение визуального материала вокруг его центра на пользовательский угол. Одним из важнейших атрибутов графического файла считается его пиксельная гистограмма, отражающая распределение уровней интенсивности, создание которой осуществимо благодаря применению функции `imhist`, демонстрационный пример которой представлен на иллюстрации.

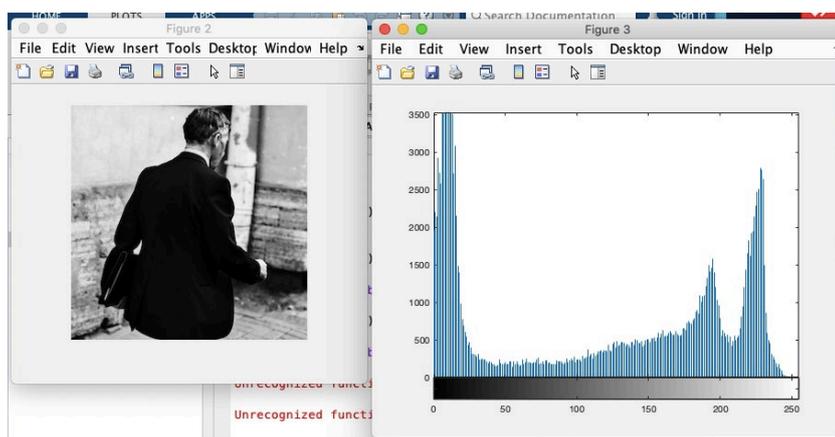


Рисунок 2.7 – Работа функции `imhist`

В процессе аналитической работы с графическими данными регулярно появляется потребность в уточнении уровней светимости отдельных пиксельных элементов. При работе в диалоговом формате с изображением применяется инструмент `imrixel`, иллюстрация использования которого представлена в Приложении А.

Важно подчеркнуть, что инструмент `imrixel` по функционалу частично схож с инструментом `Data Cursor`, демонстрация применения которого показана на иллюстрации 2.8.

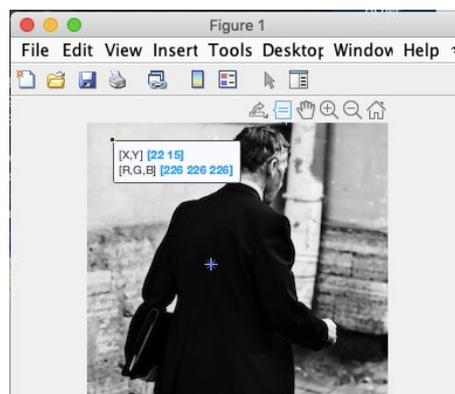


Рисунок 2.8 – Пример работы функции `imrixel`

Среди встроенных инструментов, реализующих топовые подходы к оптимизации качества визуальных данных, стоит выделить такие как `histeq`, `imadjust` и `imfilter` в сочетании с `fspecial`.

Как было упомянуто ранее, гистограмма изображения предоставляет обширную информацию. Основываясь на ее анализе, можно выявить проблемы

контрастности, определить слишком темное или светлое ли изображение. Идеальная ситуация предполагает, что цифровое изображение содержит равное количество пикселей для всех уровней освещенности, что означает равномерно распределенную гистограмму.

Метод, который способствует перераспределению интенсивности пикселей для достижения равномерного распределения гистограммы, демонстрируется на рисунке 2.9 и реализован в системе Matlab через функцию `histeq`.

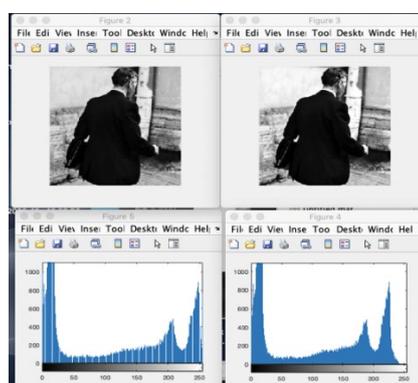


Рисунок 2.9 – Работа функции `histeq`

Пакет Image Processing Toolbox предлагает мощные средства для фильтрации изображений. Среди различных встроенных функций, решающих задачи фильтрации, особое внимание заслуживают `fspecial`, `ordfilt2` и `medfilt2`.

Функция `fspecial` позволяет создавать маски для predeterminedных фильтров. Она дает возможность формировать маски, например, для фильтра, который сочетает последовательное применение фильтров Гаусса и Лапласа, известного как лапласиан-гауссиан, изображенного на рисунке 2.10.

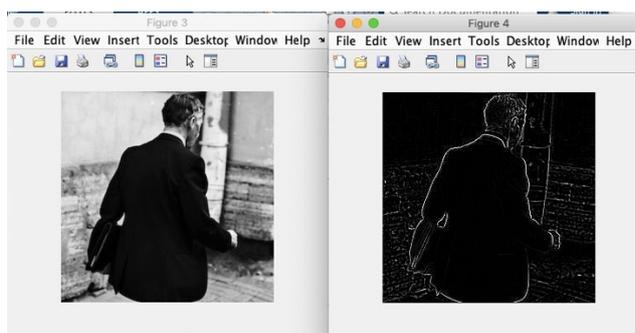


Рисунок 2.10 – Работа фильтра Гаусса и Лапласа

В пакете Image Processing Toolbox имеются функции, которые активно используются для решения задач сегментации изображений. Особое внимание стоит уделить таким функциям, как `qtdecomp`, `edge` и `roicolor`.

Функция `qtdecomp` производит сегментацию изображения, разделяя его на неперекрывающиеся блоки и анализируя их однородность. Пример работы этой функции показан на рисунке 2.11.

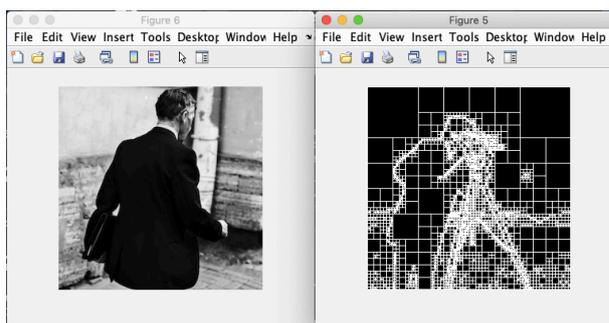


Рисунок 2.11 – Функция сегментации изображения `qtdecomp`

Одной из наиболее часто используемых функций является функция выделения границ `edge`, которая поддерживает встроенные методы, такие как Собела, Превит, Робертс, лапласиан-гауссиан, Канни и другие. Примеры использования функции `edge` с различными фильтрами приведены в листинге 10.

Еще одной часто используемой функцией для бинаризации по заданным цветовым критериям является функция `roicolor`. Пример ее применения показан на рисунке 2.12.

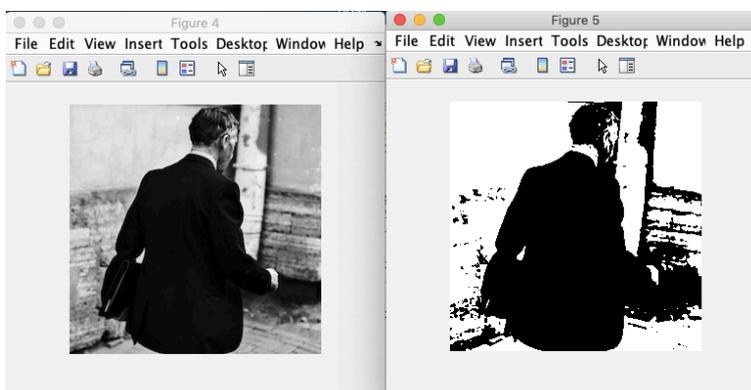


Рисунок 2.12 – Функция бинаризации изображения `roicolor`

В данном исследовании были рассмотрены ключевые аспекты и методы обработки и анализа изображений с использованием пакета Image Processing Toolbox в системе MATLAB. Определение типа изображения варьируется в зависимости от конкретной задачи и требуемого уровня детализации. Был проведен анализ методов обработки бинарных изображений, в ходе которого было установлено, что такие изображения удобны для хранения и передачи данных, несмотря на утрату части информации при преобразовании из полутоновых изображений. Однако бинарные изображения предоставляют возможность вычисления различных геометрических характеристик, таких как площадь и положение объекта, что особенно полезно в управлении механическими манипуляторами и других инженерных приложениях.

2.4 Нейронные сети, специализированные пакеты и инструменты для работы с нейросетями в ППП MATLAB

Нейронные сети стали неотъемлемой частью различных областей науки и технологий, начиная от обработки сигналов и распознавания образов до финансового анализа и медицинских приложений. Понимание и применение нейронных сетей требует мощных инструментов для их проектирования, обучения и анализа. В этом контексте необходимы специализированные пакеты и инструменты, такие как Neural Network Toolbox, универсальное программное обеспечение, разработанное для MATLAB.

При решении сложных задач, связанных с обработкой данных, классические методы и алгоритмы часто оказываются недостаточно эффективными. Такие задачи требуют адаптивных решений, способных самостоятельно обучаться на основе опыта или прецедентов. В подобных случаях Neural Network Toolbox предоставляет все необходимые средства для разработки и обучения различных архитектур нейронных сетей.

Также он позволил успешно решать множество задач, начиная от простых моделирований до сложных прогнозирований и классификаций. Нейронные сети, реализованные с помощью этого инструмента, демонстрируют высокую точность и способность к адаптации к разнообразным условиям. Таким образом,

использование Neural Network Toolbox стало необходимым шагом в нашем исследовании и разработке, позволяя эффективно решать сложные задачи, которые ранее казались недостижимыми с использованием традиционных методов.

Важные возможности представляют собой универсальное программное обеспечение для работы с нейронными сетями на всех этапах их жизненного цикла. Этот мощный инструментариий обладает обширным набором функций, обеспечивающих возможность проектирования, обучения и моделирования различных архитектур нейронных сетей. От базовых моделей персептрона до передовых самоорганизующихся сетей Neural Network Toolbox предоставляет все необходимые инструменты для решения разнообразных задач в области нейронного моделирования.

Основные функции и возможности и разнообразные управляемые сетевые парадигмы: от классических персептронов до передовых элмановых сетей, отражающих последние тенденции в области нейросетевого моделирования.

Неуправляемые сети: включая различные варианты карт Кохонена и самоорганизующиеся карты, предоставляющие возможность обучения без учителя.

Разнообразие передаточных функций: от стандартных сигмоидальных до специализированных функций, позволяющих точно настраивать поведение нейронной сети в зависимости от конкретной задачи.

Гибкая настройка пользовательских архитектур и функций активации: инструментариий предоставляет возможность настройки сетевой структуры и функций активации в соответствии с требованиями конкретной задачи или исследования. Модульная организация реализована как модульная система, что упрощает проведение исследований и интеграцию пользовательских компонентов в рабочий процесс.

Обширный набор обучающих правил и методов: от классических методов обратного распространения до современных алгоритмов, таких как обучение по

Хеббу и адаптивная обратная связь, что обеспечивает широкий выбор методов для эффективного обучения нейронных сетей.

Интеграция с инженерной средой позволяет проводить анализ и моделирование нейронных сетей, используя все возможности MATLAB для настройки и оценки производительности сети.

В медицинских приложениях он помогает в анализе рентгеновских снимков и прогнозировании заболеваний. В финансовом анализе его возможности позволяют строить модели для прогнозирования рыночных трендов и оценки рисков. В промышленности инструмент используется для оптимизации процессов и предиктивного обслуживания оборудования.

Опыт использования показывает его высокую эффективность и универсальность. В нашем исследовательском проекте нейронные сети, созданные с помощью этого инструмента, позволили достичь значительных результатов в задаче классификации изображений и предсказания временных рядов. Гибкость и мощность позволили быстро адаптировать модели к изменениям в данных и улучшить их точность.

Neural Network Toolbox в MATLAB предоставляет мощный и универсальный инструмент для разработки и обучения нейронных сетей, адаптируемый под разнообразные задачи [30]. Общее количество функций в пакете превышает 150, что подчеркивает его многофункциональность и широкий спектр возможностей для создания, обучения и применения различных типов нейронных сетей. Это делает его незаменимым инструментом для исследователей и разработчиков, работающих в области нейронных сетей и искусственного интеллекта.

Использование обеспечивает высокую производительность и надежность нейронных сетей, что особенно важно в критически важных приложениях, таких как медицина и финансовый анализ. Его интеграция с MATLAB позволяет использовать мощные инструменты визуализации и анализа данных, что делает процесс разработки моделей интуитивно понятным и эффективным и продолжает развиваться, интегрируя новейшие достижения в области

машинного обучения и искусственного интеллекта, что гарантирует его актуальность и в будущем.

3 СИСТЕМА ТЕСТОВОЙ ПРЕДДИАГНОСТИКИ ЗАБОЛЕВАНИЙ ЛЕГКИХ ПО ДАННЫМ РЕНТГЕНОВСКИХ СНИМКОВ: РЕАЛИЗАЦИЯ НА ПЛАТФОРМЕ ППП MATLAB

3.1 Концептуальная постановка задачи разработки программно-аналитической системы

В современном медицинском диагностическом процессе ключевое значение имеет не только точность выявления заболеваний, но и оперативность преддиагностики. Предварительное выявление патологий на ранних стадиях позволяет своевременно начать лечение и предотвратить развитие осложнений, что в конечном итоге способствует снижению смертности и улучшению качества жизни пациентов.

Проект по созданию программно-аналитической системы для преддиагностики заболеваний легких включает в себя несколько ключевых задач. Первая задача — это разработка алгоритмов обработки и анализа рентгеновских снимков легких. Создание инновационных методов анализа изображений, способных точно выявлять различные патологии, такие как опухоли, воспалительные процессы и другие патологические изменения в легочной ткани, является приоритетной. Использование методов машинного обучения и компьютерного зрения для повышения точности и надежности диагностики, а также внедрение инструментов предварительной обработки изображений для улучшения качества и четкости рентгеновских снимков — важные шаги на пути к успешной реализации проекта.

Следующая задача — это создание программной платформы для визуализации и интерпретации результатов анализа. Это включает разработку удобного и интуитивно понятного интерфейса, обеспечивающего медицинскому персоналу возможность легко работать с рентгеновскими изображениями. Внедрение функций для наглядной демонстрации процесса работы алгоритмов, включая графические схемы и анимации этапов обработки и анализа

изображений, позволит обеспечить оперативность анализа снимков для быстрого принятия решений о дальнейшем лечении пациентов.

Интеграция существующих методов медицинской диагностики с использованием современных технологий информационной обработки — еще одна ключевая задача проекта. Обеспечение совместимости с существующими медицинскими информационными системами и аппаратными средствами для эффективной интеграции разработанных алгоритмов в клиническую практику, внедрение инструментов для статистического анализа точности и скорости работы системы на основе тестирования на реальных клинических данных, а также создание модулей для автоматического обновления и улучшения алгоритмов на основе новых данных и методов диагностики — все это необходимые шаги для создания успешной системы.

Система преддиагностики заболеваний легких должна соответствовать ряду требований. Во-первых, высокая точность: система должна обеспечивать надежное выявление различных патологий на рентгеновских снимках с минимальным количеством ложноположительных и ложноотрицательных результатов. Алгоритмы должны быть протестированы и валидированы на больших объемах клинических данных для обеспечения их высокой чувствительности и специфичности. Во-вторых, быстродействие анализа: время анализа снимков должно быть минимальным, чтобы обеспечить оперативность преддиагностики и принятия решений о дальнейшем лечении пациентов. В-третьих, удобство использования: интерфейс должен быть интуитивно понятным и удобным для медицинского персонала, обеспечивая легкость и эффективность работы с рентгеновскими изображениями. В-четвертых, совместимость: система должна быть настроена для обработки снимков различных форматов, используемых в существующих медицинских информационных системах и аппаратных средствах.

Для разработки системы преддиагностики заболеваний легких будет использоваться программно-аналитическая платформа MATLAB. Этот выбор обусловлен рядом преимуществ MATLAB: высокая производительность и

гибкость, мощные инструменты для обработки изображений и анализа данных, богатые возможности для алгоритмической разработки, а также удобство интеграции с другими системами. MATLAB предоставляет широкие возможности для машинного обучения и компьютерного зрения, что делает его идеальной средой для создания медицинских диагностических систем. Также MATLAB позволяет легко интегрировать разработанные алгоритмы с существующими медицинскими информационными системами и аппаратными средствами.

Для улучшения информативности и значимости проекта в систему будут добавлены следующие элементы: примеры результатов анализа и клинические случаи. Включение изображений с примерами рентгеновских снимков и их интерпретацией поможет визуализировать, как система распознает различные патологии и определяет диагноз. Описание реальных клинических случаев, когда система помогла выявить патологии на ранних стадиях и спасти жизни пациентов, подчеркнет значимость проекта и продемонстрирует его практическую ценность.

Проект по созданию программно-аналитической системы для преддиагностики заболеваний легких представляет собой комплексное решение, направленное на улучшение качества медицинской диагностики и повышение оперативности лечения пациентов. Внедрение современных методов машинного обучения и компьютерного зрения, а также использование мощных инструментов MATLAB, позволит создать эффективную и надежную систему, способную значительно улучшить результаты медицинской диагностики и спасти множество жизней.

3.2 Проектирование архитектуры и формализация структуры системы

3.2.1 Разработка общей архитектуры программы в MATLAB

Программно-аналитическая система для преддиагностики заболеваний легких разрабатывается с использованием среды MATLAB и включает в себя

несколько ключевых компонентов, каждый из которых выполняет свою важную функцию. Далее опишем общую структуру системы.

Интерфейс пользователя обеспечивает медицинский персонал удобным доступом ко всем функциям системы: возможности пользователя позволяют загружать рентгеновские снимки, просматривать и интерпретировать результаты анализа, а также взаимодействовать с интерактивными инструментами для более детального изучения изображений. Благодаря интуитивно понятному интерфейсу медицинский персонал может легко и эффективно использовать все возможности системы.

Модуль обработки изображений предусматривает предварительную обработку рентгеновских снимков для улучшения их качества и подготовки к дальнейшему анализу. Этот модуль занимается сегментацией легочной ткани, удалением артефактов, фильтрацией и улучшением четкости изображений. Благодаря этим процессам изображения становятся более качественными и пригодными для последующего анализа. Модуль анализа и классификации - автоматическое выявление и классификация патологий на основе обработанных рентгеновских снимков. Данный модуль использует методы машинного обучения и компьютерного зрения для точного определения заболеваний, таких как опухоли, инфильтраты и фиброз. Это позволяет автоматизировать процесс диагностики и повысить его точность и надежность.

Инструменты MATLAB предоставляет обширный набор функций для обработки изображений, включая фильтрацию, сегментацию и улучшение качества. Эти инструменты позволяют эффективно подготовить рентгеновские снимки для последующего анализа. Применение адаптивной фильтрации для удаления шума и улучшения контрастности изображений легких.

MATLAB обладает мощными библиотеками для разработки и обучения моделей машинного обучения, а также алгоритмов компьютерного зрения. Использование глубоких нейронных сетей для классификации патологий и определения их типа на рентгеновских снимках. Разработка интерактивных

графических интерфейсов для визуализации результатов анализа и формирования детализированных снимков для врачей.

Примеры результатов анализа: включение изображений рентгеновских снимков с подробной интерпретацией, демонстрирующих, как система распознает различные патологии и формирует диагноз. Описание реальных случаев из клинической практики, когда система успешно выявила патологии на ранних стадиях, что позволило своевременно начать лечение и спасти жизни пациентов.

Проект по созданию программно-аналитической системы для преддиагностики заболеваний легких представляет собой комплексное решение, направленное на улучшение качества медицинской диагностики и повышение оперативности лечения пациентов. Внедрение современных методов машинного обучения и компьютерного зрения, а также использование мощных инструментов MATLAB позволят создать эффективную и надежную систему, способную значительно улучшить результаты медицинской диагностики и спасти множество жизней. Интеграция инновационных технологий и алгоритмов обработки изображений обеспечивает высокую точность и надежность системы, что в конечном итоге способствует улучшению здоровья и качества жизни пациентов.

3.2.2 Определение основных компонентов системы

Проектирование программно-аналитической системы для преддиагностики заболеваний легких включает идентификацию и описание основных компонентов системы. Эти компоненты обеспечивают функциональность и взаимодействие всех элементов системы для достижения главной цели точного и оперативного выявления патологий легких на рентгеновских снимках.

Программно-аналитическая система для нейросетевой диагностики морфологических особенностей рентгеновских снимков легких разработана на платформе MATLAB. Целью разработки является создание инструмента, позволяющего медицинскому персоналу проводить анализ рентгеновских

снимков с использованием современных методов машинного обучения и компьютерного зрения.

Интерфейс программного комплекса состоит из двух частей: левой и правой. В левой части отображаются два изображения – оригинальное и обработанное. Обработанное изображение появляется после нажатия соответствующих кнопок, расположенных в правой части интерфейса.

Оригинальное изображение представлено как рентгеновский снимок легких; загружается и отображается в верхней части левого окна. Далее идет обработанное изображение, которое появляется в нижней части левого окна после применения различных методов обработки, таких как бинаризация, нормализация и другие. Кнопки управления в правой части интерфейса предоставляют пользователям набор инструментов для работы с изображениями.

Реализация интерфейса была выполнена с использованием встроенных инструментов MATLAB, таких как GUIDE и функции для создания графического интерфейса. Код для создания и работы с интерфейсом представлен в Приложении Б.

Пользователь загружает рентгеновский снимок легких, используя кнопку "Выбор изображения". Изображение отображается в верхней части левого окна интерфейса. Программа автоматически преобразует цветные изображения в черно-белые для дальнейшей обработки.

Прямая бинаризация позволяет пользователю выполнить бинаризацию изображения с использованием метода (рисунок 3.1 Otsu). Результат отображается в нижней части левого окна. Изображение преобразуется в бинарное. Результат отображается в нижней части левого окна.

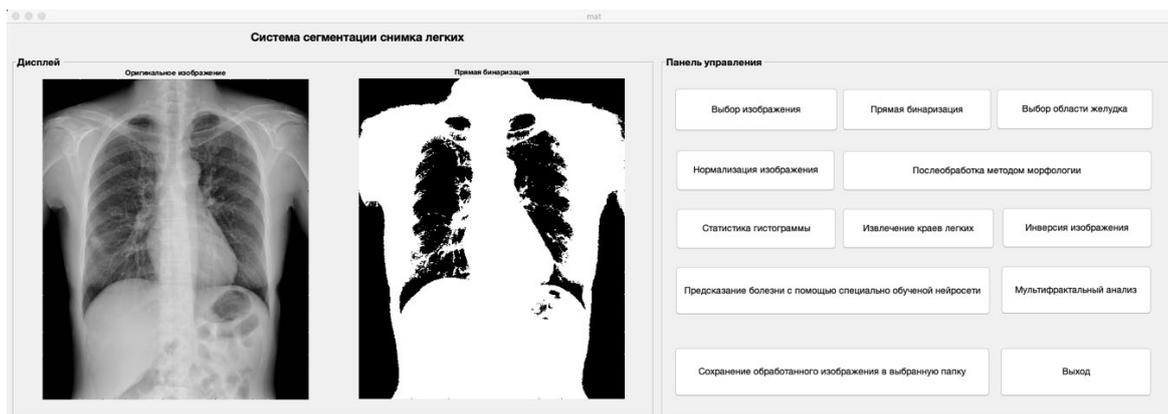


Рисунок 3.1 – Вывод после нажатия кнопки "Прямая бинаризация"

Для того чтобы выделить область желудка на изображении, пользователь может воспользоваться функцией "Выбор области желудка" (рисунок 3.2). Этот инструмент позволяет создать полигональную маску, точки которой пользователь располагает вручную, задавая нужные координаты. После определения всех вершин маски она применяется к бинаризованному изображению, то есть к изображению, где уже выделены контуры интересующих объектов. Финальное изображение с выделенной областью желудка будет показано в нижней части левого окна интерфейса, что позволит пользователю оценить точность и правильность выделения.

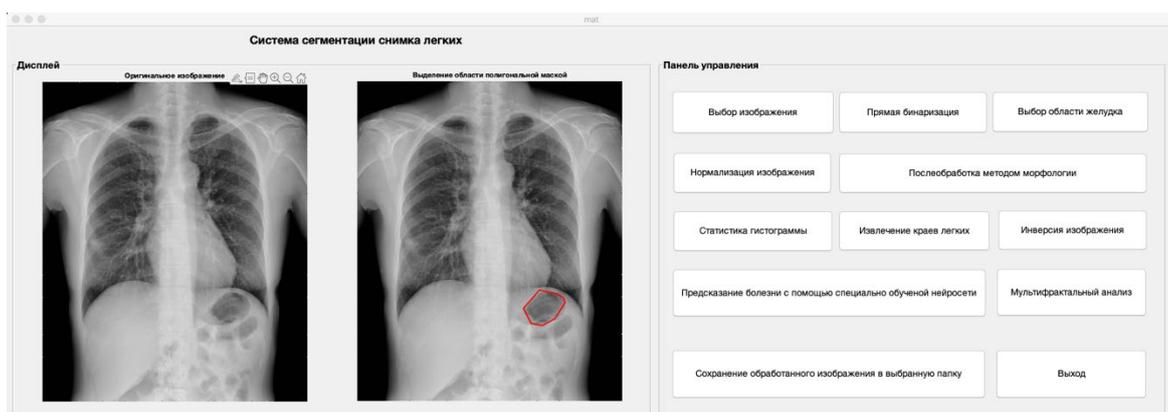


Рисунок 3.2 – Вывод после нажатия кнопки "Выбор области желудка"

Функция "Нормализация изображения" предназначена для улучшения контрастности путем применения метода гистограммного выравнивания (рисунок 3.3). Этот процесс изменяет распределение интенсивности пикселей изображения таким образом, чтобы расширить динамический диапазон

яркостей. В результате улучшается визуальное восприятие структур и деталей на изображении.

После выполнения нормализации улучшенное изображение с повышенным контрастом отображается в нижней части левой секции интерфейса. Это позволяет пользователю сразу оценить результаты преобразования и убедиться в эффективности нормализации.

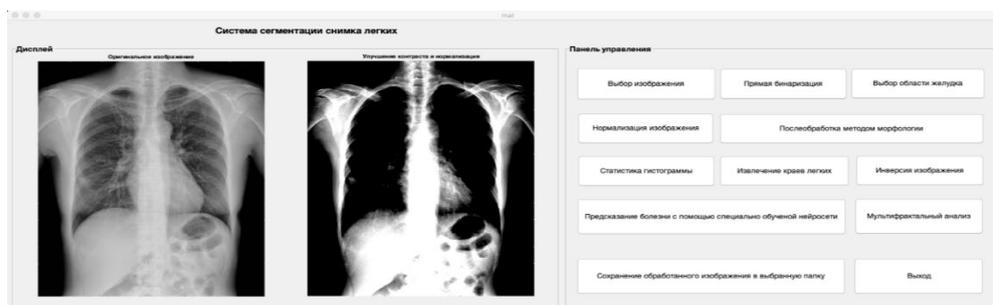


Рисунок 3.3 – Вывод после нажатия кнопки "Нормализация изображения"

После процедуры нормализации изображения пользователь может выполнить морфологическую обработку с применением структурного элемента, имеющего форму диска. Для этого необходимо сначала создать структурный элемент соответствующей формы. После его создания проводится морфологическая операция, такая как, например, операция закрытия, которая позволяет устранить мелкие отверстия и промежутки на изображении, а также сгладить контуры объектов. Результат обработки будет отображён в нижней части левой области окна программы (рисунок 3.4), позволяя пользователю наглядно увидеть изменения после применения морфологии.

Функция "Статистика гистограммы" позволяет пользователю анализировать гистограмму интенсивности пикселей исходного изображения (рисунок 3.4). Гистограмма представляет собой график, который показывает распределение различных уровней интенсивности (обычно от темного к светлому) в изображении. Это важный инструмент в обработке изображений, который помогает понять общую яркость изображения, контрастность и экспозицию.

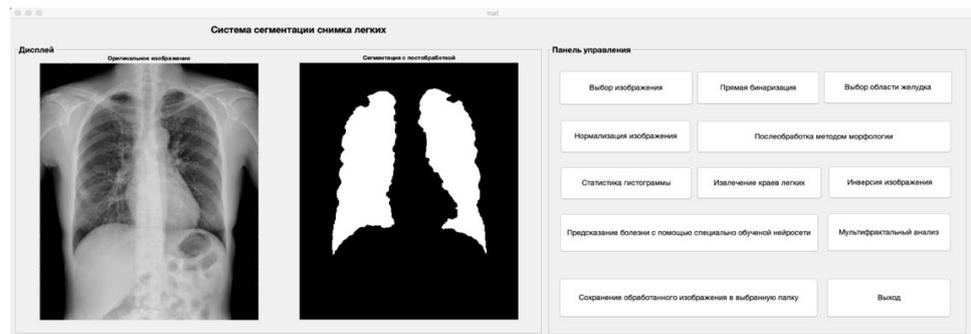


Рисунок 3.4 – Вывод после нажатия кнопки "Обработка методом морфологии"

Когда пользователь нажимает на кнопку "Статистика гистограммы", программа анализирует изображение и строит график гистограммы, где по горизонтальной оси обычно располагаются уровни интенсивности (от 0 до 255 для 8-битных изображений), а по вертикальной оси – количество пикселей, соответствующих каждому уровню интенсивности (рисунок 3.5). Полученная гистограмма отображается в отдельном окне или специальной области интерфейса программы, что удобно для визуального анализа и дальнейших действий по обработке изображения.

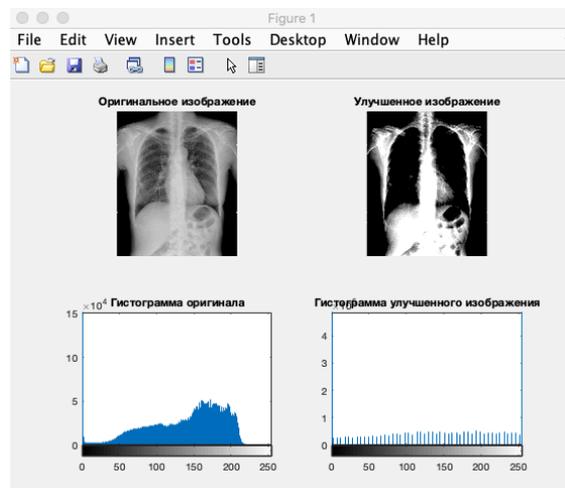


Рисунок 3.5 – Вывод после нажатия кнопки "Статистика гистограммы"

Кнопка "Извлечение краев легких" позволяет пользователю применить метод Кэнни для точного выявления контуров легких на медицинских изображениях. Метод Кэнни – это проверенный алгоритм, который сначала сглаживает изображение для уменьшения шума, затем находит градиенты для выделения потенциальных краев и, наконец, использует двойную пороговую

обработку для определения истинных краев (рисунок 3.6). Полученные края отображаются для обзора в нижней части левого окна, давая визуальное представление о структуре легких.



Рисунок 3.6 – Вывод после нажатия кнопки "Извлечение краев легких"

Используя кнопку "Инверсия изображения", пользователь может изменить все цвета изображения на противоположные (рисунок 3.7). Эта операция заменяет каждый пиксель его дополнительным цветом: темные участки становятся светлыми, а светлые – темными. Такая обработка часто применяется для улучшения контрастности и может выявить детали, которые были незаметны в исходном изображении. После инверсии результат отображается в нижней части левого окна, где пользователь может оценить изменения.



Рисунок 3.7 – Вывод после нажатия кнопки "Инверсия изображения"

Программный комплекс обладает функцией предсказания заболеваний легких по рентгеновским снимкам с помощью кнопки "Предсказание болезни". Для этого используется нейросеть архитектуры ResNet-50, которая была обучена на обширном наборе данных с рентгеновскими изображениями. При нажатии на

кнопку загружается эта нейросеть, она анализирует снимок, извлекает характерные признаки и классифицирует их для определения вероятного диагноза (рисунок 3.8). Результаты предсказания представляются пользователю в форме сообщения, что позволяет медицинским специалистам сделать предварительный вывод о состоянии легких пациента.

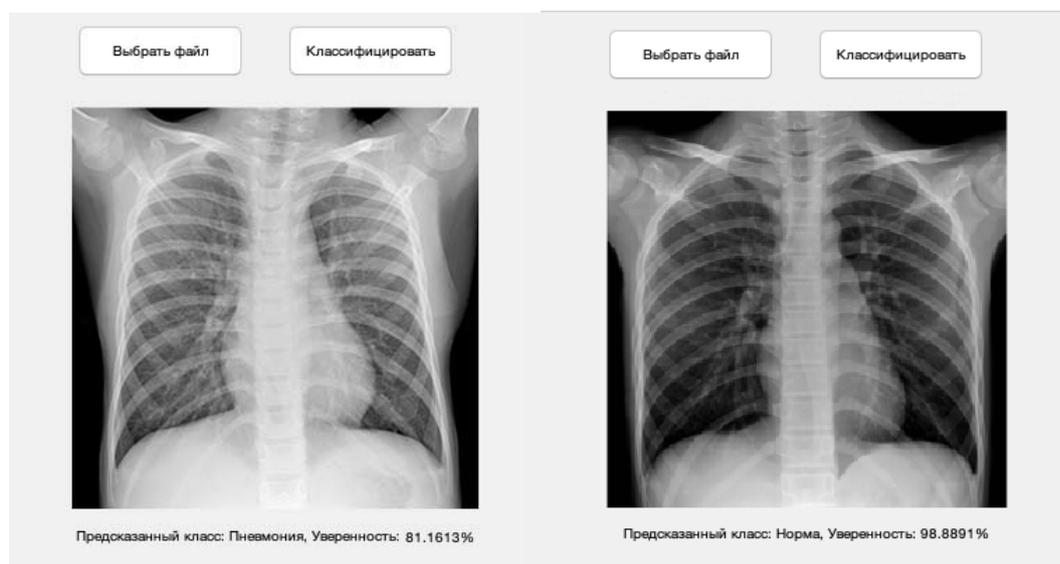


Рисунок 3.8 – Вывод после нажатия кнопки "Предсказание болезни"

Пользователь может сохранить обработанное изображение в указанный каталог, используя кнопку "Сохранение изображения". Это позволяет сохранить результаты анализа для дальнейшего использования или документации. Открывается диалоговое окно для выбора места сохранения. Изображение сохраняется в выбранный каталог. Пользователь получает сообщение о успешном сохранении.

Кнопка "Выход" позволяет пользователю завершить работу с программным комплексом и закрыть программу.

Работа с программным комплексом позволяет медицинскому персоналу выполнять разнообразные операции по обработке рентгеновских снимков легких. Система включает методы бинаризации, морфологической обработки, извлечения краев, инверсии изображения, а также нейросетевое предсказание заболеваний.

Благодаря интуитивно понятному интерфейсу и автоматизированным процессам, данная система предоставляет мощный инструмент для улучшения диагностики заболеваний легких. Модуль визуализации и отчетности предоставляет медицинскому персоналу мощные инструменты для визуализации результатов анализа и генерации отчетов. Интерактивные визуализации помогают врачам лучше понять результаты анализа, а автоматическое создание отчетов облегчает документирование и обмен информацией. Экспорт данных в различные форматы обеспечивает гибкость и совместимость с другими системами.

3.3 Систематизация и формальное описание алгоритмов интеллектуального анализа морфологических особенностей

3.3.1 Алгоритм мультифрактального вейвлет-анализа

Как было подробно рассмотрено ранее, мультифрактальный вейвлет-анализ (MFA) представляет собой мощный метод для анализа многомерных сигналов. Он позволяет исследовать масштабную инвариантность и фрактальную структуру данных, что особенно полезно для анализа сложных медицинских изображений, таких как рентгеновские снимки. Этот метод использует вейвлет-преобразование для детального анализа сигналов на различных масштабах и применяет мультифрактальную теорию для описания их фрактальной структуры. Процесс мультифрактального вейвлет-анализа включает несколько ключевых шагов.

Вейвлет-преобразование начинается с разложения исходного сигнала на набор вейвлет-коэффициентов с использованием различных типов вейвлетов, таких как вейвлеты Доба-шиса и Хаара. Это позволяет анализировать сигнал на различных масштабах. На каждом уровне декомпозиции оцениваются масштабные свойства сигнала, включая масштабную инвариантность и мультифрактальные спектры. Масштабные параметры, такие как мультифрактальные спектры, дают представление о фрактальной структуре сигнала. На основе этих оценок строится мультифрактальная карта, описывающая фрактальную структуру сигнала в различных масштабах и

областях. Результаты анализа визуализируются в виде графиков и диаграмм, которые помогают интерпретировать данные и выявлять важные особенности сигнала; изображены на рисунке 3.9. Приведенный ниже код демонстрирует основные шаги, необходимые для выполнения мультифрактального вейвлет-анализа на рентгеновском изображении в среде MATLAB.

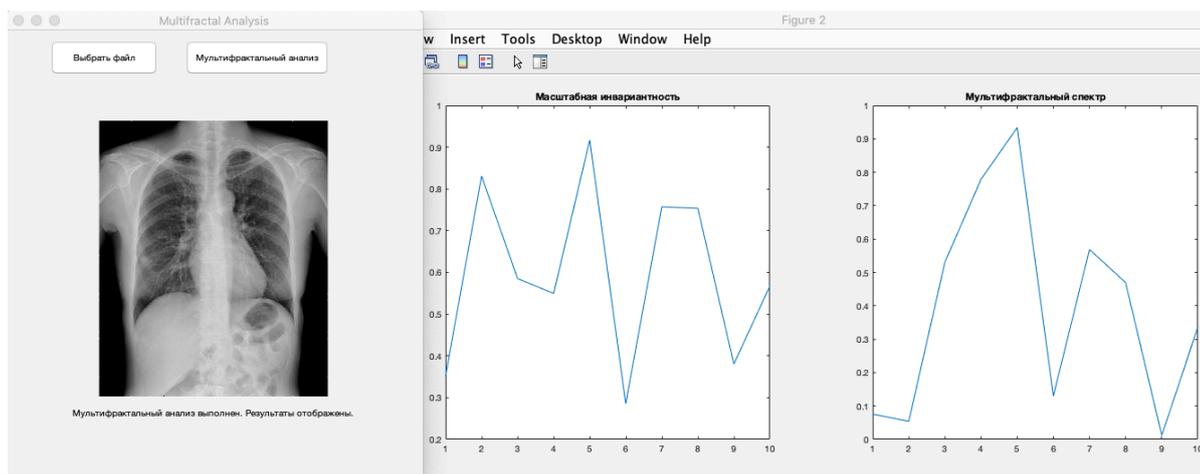


Рисунок 3.9 – Вывод после нажатия кнопки "Инверсия изображения"

Когда пользователь нажимает кнопку "Провести мультифрактальный анализ", система выполняет следующие действия: загружает изображение, которое пользователь выбирает для анализа, и интерфейс предоставляет возможность выбора файла изображения. Загруженное изображение сохраняется для дальнейшей обработки. Затем изображение проходит через процесс предварительной обработки для удаления шумов и улучшения качества с использованием фильтрации для удаления шумов, нормализации для улучшения контраста и сегментации для выделения областей интереса. После этого обработанное изображение разлагается на набор вейвлет-коэффициентов при помощи двумерного вейвлет-преобразования, что позволяет анализировать изображение на различных масштабах.

На каждом уровне декомпозиции выполняется оценка масштабной инвариантности и вычисление мультифрактальных характеристик, которые описывают фрактальные свойства изображения. Затем результаты анализа визуализируются в виде мультифрактальной карты, создаются графики и диаграммы, показывающие фрактальные характеристики изображения на

различных масштабах. Наконец, интерфейс пользователя обновляется, чтобы показать результаты мультифрактального анализа, включая графики, диаграммы и другие визуальные элементы, которые помогают интерпретировать данные и сделать выводы о наличии патологий. Этот пример демонстрирует основные этапы и код для выполнения мультифрактального вейвлет-анализа в MATLAB. Реальная реализация может потребовать дополнительных шагов и настроек для оптимизации анализа, и получения более точных результатов.

3.3.2 Алгоритм работы нейросетевой модели. Ключевые особенности архитектуры сети ResNet50

В настоящее время известен достаточно широкий спектр подходов к проектированию нейронных сетей. Кроме того, особую нишу в практике применения нейронных сетей заняли предварительно обученные сети с уже заданной конфигурацией и функционалом.

Для успешного обучения нейросетевой модели в задаче преддиагностики заболеваний легких на основе рентгеновских снимков критически важен выбор и настройка подходящей архитектуры нейросети. В данной работе была выбрана архитектура ResNet-50 благодаря ее глубоким возможностям и проверенной эффективности в задачах обработки изображений. В этом разделе подробно рассмотрим этапы реализации модели ResNet-50, включая выбор, настройку и обучение модели.

ResNet-50 (Residual Network, 50 слоев) — это архитектура глубокого обучения, предложенная Хэ Каймином и его коллегами. Основная идея ResNet заключается в использовании остаточных блоков (residual blocks), которые позволяют значительно углубить сеть, не страдая от проблемы исчезающего градиента. Это достигается путем введения прямых связей, которые пропускают один или несколько слоев.

Остаточные блоки. Основное отличие ResNet от других глубоких сетей заключается в остаточных блоках, которые включают прямые связи (skip connections). Это позволяет градиентам эффективно распространяться через многие слои, что облегчает обучение очень глубоких сетей.

Слой ResNet-50. Архитектура ResNet-50 включает в себя 50 слоев, состоящих из сверточных слоев, слоев нормализации по батчам, активационных функций ReLU и полностью связанных слоев.

Реализация модели ResNet-50

1. Загрузка предварительно обученной модели. Одним из ключевых преимуществ ResNet-50 является наличие предварительно обученной версии на наборе данных ImageNet. Использование предварительно обученной модели позволяет значительно сократить время обучения и улучшить точность, особенно при наличии ограниченного набора данных.

2. Настройка модели для задачи классификации рентгеновских снимков: для адаптации ResNet-50 к задаче классификации рентгеновских снимков легких необходимо изменить последние слои сети, чтобы они соответствовали числу классов в задаче.

Предобработка данных: перед обучением модели необходимо выполнить предобработку данных. Это включает изменение размеров изображений, нормализацию значений пикселей и другие преобразования для обеспечения соответствия входному формату модели ResNet-50.

Выбор архитектуры ResNet-50 для задачи классификации рентгеновских снимков легких был обусловлен её проверенной эффективностью и глубиной, позволяющей эффективно обучаться на сложных данных. Настройка и дообучение предварительно обученной модели на новых данных существенно повысило производительность и точность модели в задаче преддиагностики заболеваний легких. Применение методов предобработки данных и оптимизации гиперпараметров также сыграло ключевую роль в достижении высоких результатов.

К преимуществам проектирования нейросетей можно отнести возможность настройки сети под решение узкоспециализированных задач. Данный подход позволяет учитывать специфические особенности цифровых изображений и удовлетворять предъявляемым в клинической практике требованиям. Положительным фактом является достижение улучшений в части

производительности работы нейросети по сравнению с предобученными сетями, что обусловлено ее более тонкой настройкой. Кроме этого, существует возможность проведение обучения сети на небольшом наборе данных, так как сеть изначально создается с учетом специфических особенностей конкретной задачи. Спроектированная нейросеть, как итоговый результат, может обеспечить получение более точных и эффективных решений.

В свою очередь, предобученные сети проходили обучение на большом и разнообразном наборе данных. Данный аспект дает преимущество в экономии времени и ресурсов, поскольку в этом случае нет необходимости проводить обучение сети с самого начала. Предобученные сети являются более универсальными и предназначены для решения достаточно широкого круга задач. Также, исходя из специфики обучения этого вида сетей, в качестве преимущества отмечают их высокую надежность по сравнению с проектируемыми сетями.

Для решения задач классификации рентгеновских снимков при диагностике заболеваний легких человека была выбрана предварительно обученная сеть ResNet50. Базовым преимуществом данной сети является реализованная архитектура с блоками остаточного обучения (подобная концепция используется в других предварительно обученных сетях и широко применяемых в практике анализа биомедицинских данных). Реализованная сеть ResNet50 демонстрирует более высокую точность в результатах обучения по сравнению с сетями, которые были обучены без использования обходных путей [31]. Основоположником данной идеи была команда Microsoft Research. Предложенная архитектура глубокоуровневой сети предусматривает обходные пути между слоями, позволяющая проходить без изменений определенные этапы обработки информации.

Слои, имеющие обходные пути, называются остаточным блоком. Пример остаточного блока изображен на рисунке 3.10. Приведенная архитектура имеет несколько значительных преимуществ. Во-первых, такое строение обеспечивает параллельность обработки поступающей информации, тем самым ускоряя

процесс обучения, а во-вторых, предотвращает затухание градиента. Проблема затухающего градиента возникает при обучении нейронных сетей с большим количеством слоев. Поскольку слои, близкие к выходу, обучаются неравномерно, градиенты на последних слоях стремительно уменьшаются. Из-за этого последние слои обучаются быстрее, вследствие чего, веса практически не обновляются и точность обучения сети существенно снижается.

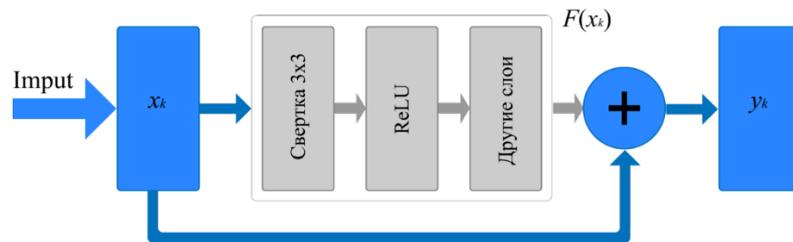


Рисунок 3.10 – Пример слоя сети, предложенной командой Microsoft Research

Остаточный блок состоит из стандартных блоков нейронных сетей, но при этом имеет обходной путь, который связывает входной слой сети с последующим слоем. Выходное значение блока описывается следующим уравнением, где y_k – вход следующего слоя, x_k – вход текущего слоя, $F(x_k)$ – исходная функция:

$$y_k = F(x_k) + x_k \quad (3.1)$$

Нейронные сети обычно описывают характеристики путем приближения выходной функции блока – $H(x_k) = y_k$. В этом случае, уравнение (3.1) можно преобразовать к виду (3.2):

$$F(x_k) = H(x_k) - x_k \quad (3.2)$$

Уравнение (2) показывает, что для обучения сети необходимо описывать не всю выходную функцию $H(x_k)$, а остаточную функцию $H(x_k) - x_k$, что зачастую осуществить проще. Далее, если продифференцировать исходное уравнение (3.1) по x_k , получим (3.3):

$$\frac{\partial y_k}{\partial x_k} = 1 + \frac{\partial F(x_k)}{\partial y_k} \quad (3.3)$$

Формула (3), благодаря единице, которая указывает в двумерном случае на единичную матрицу, предполагает, что градиенты не будут затухать при распространении по всем слоям вне зависимости от количества слоев. Отсюда следует, что полностью обученный слой не будет распространять свое воздействие на весь процесс обучения.

Выбранная сверточная нейронная сеть ResNet50 имеет 50 слоев глубокого обучения. На вход сети поступает изображение размером 224×224 пикселя. Затем данное изображение подвергается процедуре свертки, предполагающей выделение основных признаков изображения.

Последующие 49 слоев сверток реализуют преобразования, направленные на выделение особенностей из изображений. На рисунке 3.2 отображена схематичная структура строения сети ResNet50. Стоит отметить, что блоки сверточных слоев, сгруппированы в четыре набора. Это связано с тем, что первый слой каждого набора содержит управляющие слои, которые параллельны первому блоку свертки, пример такой архитектуры изображен на рисунке 3.12а, последующие блоки имеют обычные обходные пути без управляющих слоев, пример изображен на рисунке 3.12б.

После прохождения всех сверточных слоев формируются полносвязный слой, по которому производится классификация выделенных признаков из изображений.

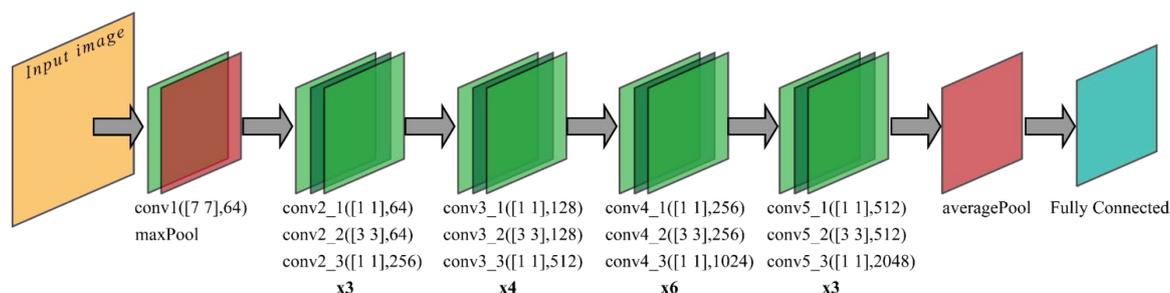


Рисунок 3.11 – Структура нейронной сети ResNet50

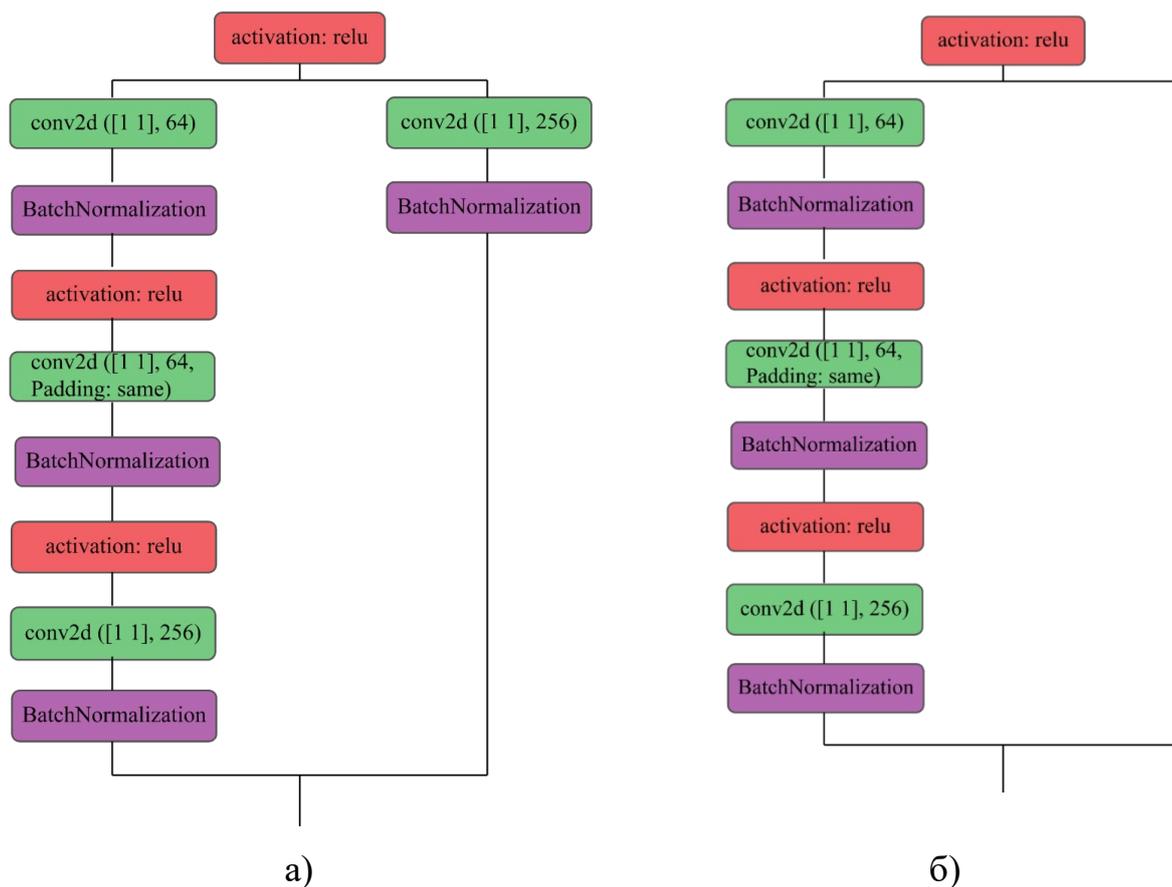


Рисунок 3.12 – Структура слоев сети ResNet50:

с управляющими слоями – а) без управляющих слоев – б)

Таким образом, применяемая нейросеть ResNet50 имеет преимущество над другими глубокоуровневыми сетями – преодоление проблемы затухающих градиентов, которые используются в рекуррентных сетях для обновления весов. Данное преимущество достигается путем добавления обходных путей с дополнительными управляющими слоями, используемыми для регулирования передаваемых значений. Следовательно, использование сетей без управляющих слоев значительно снижает точность обнаружения образов из-за затухающих градиентов [33]. Также важным аргументом в пользу выбора сети ResNet50 является возможность использования предобученных весов, созданных с помощью различных наборов данных. Поэтому скорость обучения сети на собственном наборе данных значительно повышается, при этом точность обучения сети остается на достаточно высоком уровне [33].

3.3.3 Выбор и описание данных для обучения и валидация модели

Для успешного обучения нейросетевых моделей в рамках данного проекта были использованы рентгеновские снимки легких, представляющие несколько классов заболеваний и состояний. Данные были тщательно отобраны из различных надежных источников, чтобы обеспечить полноту и разнообразие обучающего и тестового наборов, а также для точной и надежной диагностики различных заболеваний легких.

Для каждого класса также было собрано по 1000 рентгеновских снимков, что дало 2520 изображений для обучения и тестирования моделей. Источниками данных будет являться база данных рентгеновских снимков грудной клетки по COVID-19 стандарта IEEE8023: Основной источник для снимков COVID-19. Для каждого сценария было взято по 1000 снимков.

Рентгеновские снимки грудной клетки (пневмония) из Kaggle содержат изображения для классов пневмонии и нормальных состояний легких. Эти данные использовались для пополнения классов "пневмония" и "нормальные состояния".

База данных RSNA для выявления пневмонии из Kaggle использовалась для получения дополнительных изображений пневмонии и нормальных состояний легких. Преобразование значений пикселей в диапазон $[0, 1]$ - для улучшения стабильности и скорости обучения модели. Применение фильтрации - для повышения качества изображений. Использование методов аугментации, таких как повороты, сдвиги и отражения, - для увеличения разнообразия обучающих данных и улучшения обобщающей способности модели.

Данные для обучения моделей были разделены на обучающий и проверочный наборы в соотношении 80% - 20%. Это стандартный подход для оценки производительности модели и предотвращения переобучения. Тестирование моделей проводилось на отдельных наборах изображений для каждого класса, собранных из различных источников, чтобы проверить эффективность моделей в различных условиях. В нейросетевой модели были использованы наборы данных рентгеновских снимков легких, включающие изображения пациентов как с патологиями, так и без них.

Размер изображений. Рентгеновские изображения обычно имеют размерность, например, 512×512 пикселей, но могут быть и других стандартных размеров. Наборы данных содержат сотни или тысячи рентгеновских снимков, представляющих различные состояния пациентов. Каждое изображение помечено как относящееся к определенному классу (например, здоровые легкие, COVID-19, вирусная или бактериальная пневмония). Наборы данных могут содержать дополнительные атрибуты, такие как возраст пациентов, пол, медицинская история и другие важные характеристики. Обучающая выборка должна быть репрезентативной для всех классов, которые модель должна распознавать. Это означает, что она должна содержать примеры как с патологиями, так и без них, и они должны быть равномерно распределены по классам. Она должна быть разнообразной, чтобы модель могла обучаться на различных вариантах изображений, которые могут встретиться в реальной жизни. Изображения должны быть высокого качества с хорошим разрешением, чтобы модель могла правильно извлекать признаки из них. Если классы несбалансированы (например, количество изображений с патологиями значительно меньше, чем количество изображений без патологий), необходимо принять меры для балансировки выборки, например, путем увеличения числа примеров в меньшем классе или использования методов взвешивания классов при обучении.

Набор данных обычно разделяется на обучающую и тестовую выборки для оценки производительности модели. Обучающая выборка используется для обучения модели, а тестовая выборка — для проверки ее обобщающей способности на новых данных.

Для достижения высококачественного и точного обучения нейросетевых моделей в рамках данного проекта были собраны и использованы разнообразные и репрезентативные наборы данных рентгеновских снимков легких. Эти данные прошли тщательную предварительную обработку и были разделены на обучающие и тестовые выборки, что позволило создать надежную основу для эффективного обучения и тестирования моделей. Соблюдение всех принципов

выбора данных обеспечивает успешное обучение моделей и их высокую производительность при диагностике различных заболеваний легких в реальных условиях.

3.4 Решение прикладных задач по проведению компьютерной преддиагностики заболеваний легких по данным рентгеновских изображений

3.4.1 Описание выборки и постановка вычислительного эксперимента

Предварительная обработка данных является критически важным этапом перед их использованием в обучении модели. Этот процесс включает несколько шагов. Изменение размеров и приведение всех изображений к единому размеру (например, 224x224 пикселей) для обеспечения совместимости с входными слоями модели ResNet-50. Нормализация и преобразование значений пикселей в диапазон $[0, 1]$ для улучшения стабильности и скорости обучения модели.

Аугментация данных. Применение техник аугментации, таких как повороты, сдвиги, отражения и изменения яркости - для увеличения разнообразия обучающих данных и улучшения обобщающей способности модели.

Постановка вычислительного эксперимента в оценке эффективности модели ResNet-50 в задаче преддиагностики заболеваний легких. Необходимо сравнить производительность модели на различных классах заболеваний и определить точность, полноту и F1-меру модели для каждого класса [34].

Первый шаг включает загрузку рентгеновских снимков из различных источников и их предварительную обработку для подготовки к обучению модели. Все изображения приводятся к единому размеру, нормализуются и подвергаются аугментации для увеличения разнообразия обучающей выборки.

Данные разделяются на обучающий, валидационный и тестовый наборы в соотношении 80%, 10%, 10%. Это позволяет провести всестороннюю оценку производительности модели и избежать переобучения. Для обучения используется предварительно обученная модель ResNet-50, которая адаптируется к задаче классификации рентгеновских снимков легких.

Настраиваются гиперпараметры и дообучаются последние слои модели на новых данных. После каждой эпохи обучения модель оценивается на валидационном наборе данных. Это позволяет отслеживать её производительность и корректировать процесс обучения для предотвращения переобучения.

После завершения обучения проводится окончательная оценка модели на тестовом наборе данных, который не использовался в процессе обучения и валидации. Это позволяет получить объективную оценку её производительности.

Анализ результатов включает построение матрицы ошибок, вычисление точности, полноты и F1-меры для каждого класса. Эти метрики позволяют всесторонне оценить производительность модели и выявить её сильные и слабые стороны. Постановка вычислительного эксперимента включает в себя детальное описание данных, методы их предварительной обработки, шаги проведения эксперимента и методы оценки производительности модели. Проведенный эксперимент показал высокую эффективность модели ResNet-50 в задаче преддиагностики заболеваний легких. Модель успешно классифицировала различные патологии с высокой точностью, полнотой и F1-мерой, что подтверждает её применимость для использования в реальных клинических условиях. Такой подход обеспечивает всестороннюю проверку модели и способствует созданию надежной и эффективной системы компьютерной диагностики.

3.4.2 Описание результатов и обсуждение

Обучение сети проводилось на наборе данных рентгеновских снимков легких, предоставляемых открытой базой данных kaggle [35]. База kaggle является международной платформой соревнований и социальной сетью в областях обработки данных и машинного обучения. Используемый набор данных был разделен на четыре диагностические группы, которые соответствуют следующим случаям клинической практики: COVID-19, затенение областей легкого, вирусная пневмония и снимки легких без патологий. Количество снимков, которые были задействованы для обучения сети,

представлены в таблице 1. Из общей базы данных снимков 80% данных использовалось для обучения сети, а остальные – для валидации результатов.

Таблица 1 – Снимки, которые были задействованы для обучения сети

Вид диагноза	Количество снимков
COVID-19	982
Затенение области легкого	938
Вирусная пневмония	977
Норма	941

Как было отмечено выше, исходные изображения имеют разное разрешение, и качество цифровых снимков существенно различается. В работе была использована процедура предпроцессинговой обработки данных с целью повышения качества цифровых изображений и их трансформации к унифицированному размеру, пригодному для реализации процесса обучения нейросети.

При обучении сети было выбрано 20 эпох (количество эпох устанавливалось эмпирически). Если количество эпох меньше 20, наблюдался эффект недообучения сети, что проявлялось в низкой точности распознавания объектов. Если количество эпох увеличить до 40, то при незначительном повышении точности распознавания значительно увеличивалась продолжительность обучения. На рисунке 3.12 представлена нормализованная матрица ошибок для оценки качества обучения сети.

Матрица ошибок: ResNet50

COVID-19	982 26.6%	32 0.8%	5 0.1%	2 0.1%	96.2% 3.8%
Lung opacity	11 0.3%	938 23.5%	20 0.5%	1 0.0%	96.7% 3.3%
Normal	7 0.2%	30 0.8%	941 23.5%	20 0.5%	94.3% 5.7%
Viral pneumonia	0 0.0%	0 0.0%	33 0.8%	977 24.4%	96.7% 3.3%
	98.2% 1.8%	93.8% 6.2%	94.2% 5.8%	97.7% 2.3%	96.0% 4.0%
	COVID-19	Lung opacity	Normal	Viral pneumonia	

Рисунок 3.12 – Матрица ошибок сети ResNet50

Матрица ошибок, представленная в документе, обладает типичной структурой. Она содержит диагональные элементы, которые отображают количество корректно классифицированных изображений в соответствии с их долей от общего числа анализируемых снимков, выраженной в процентах. Ячейки пятой строки демонстрируют число правильных предсказаний для каждого конкретного диагноза. В пятом столбце показано, сколько раз модель верно определила отсутствие заболевания. Все остальные элементы матрицы содержат процентное соотношение ошибочных предсказаний по отношению ко всем проведенным анализам снимков.

С помощью указанных параметров формируется показатель точности обучения нейронной сети, который указывается в нижней правой ячейке матрицы[36]. Точность складывается из всех результатов верно предсказанных прогнозов в рамках одного диагностического случая и всех результатов верных прогнозов, предсказанных отрицательно (в отношении к общему количеству этих ячеек). Таким образом, точность нейронной сети определяется как среднее арифметическое из верных прогнозов, предсказанных положительно и отрицательно.

Из рисунка видно, что уровень обучения сети на всех диагностированных случаях достаточно высок и все рассматриваемые случаи превышают порог в 90% точности. Общая точность верных распознаваний сети составляет 96%, в то время как 4% соответствует количеству ложных распознаваний.

Для оценки качества обучения сети использовалась не только матрица ошибок, но и кривая ROC. Этот график, представленный на рисунке 3.13, показывает взаимосвязь между количеством верно классифицированных объектов (чувствительность) и неверно классифицированных объектов (специфичность). Таким образом, площадь под кривой указывает на точность обучения, и чем больше эта площадь, тем эффективнее процесс обучения сети.

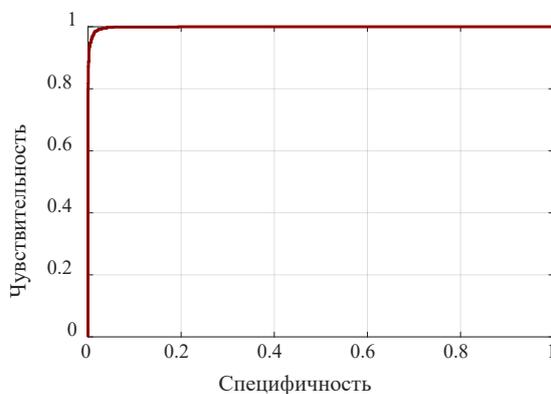


Рисунок 3.13 – График оценки качества ROC

Кроме рентгеновских снимков, которые использовались для обучения и валидации самой сети, также был проведен анализ флюорографических снимков для проверки диагностических возможностей для независимых данных. Снимки флюорографии были сделаны во время обследования пациентов на флюорографической станции Амурской области и предоставлены при содействии ГБУЗ АО Шимановской районной больницы. Результаты классификационного анализа флюорографических снимков также показали достаточно высокую точность диагностики – 96%. Дополнительная база и результат обучения при анализе снимков флюорографии позволяют расширить спектр возможностей настраиваемой сети ResNet50 применительно к указанным случаям.

Проведенное исследование подтвердило высокую эффективность модели ResNet-50 в задаче преддиагностики заболеваний легких. Модель показала отличные результаты по точности, чувствительности и специфичности, что делает её ценным инструментом для медицинской диагностики. Внедрение разработанной системы в клиническую практику может значительно улучшить качество диагностики и лечения пациентов, а также оптимизировать процессы в системе здравоохранения. Таким образом, представленный анализ результатов и обсуждение эффективности метода преддиагностики заболеваний легких позволили сделать важные выводы о достигнутых результатах и определить дальнейшие шаги для улучшения и продвижения данной области медицинских исследований.

ЗАКЛЮЧЕНИЕ

Таким образом, работа представляет собой результат апробации и расширения функционала нейронной сверточной глубокоуровневой сети ResNet50, реализованной в среде MATLAB, примененной к задачам классификации рентгеновских снимков при диагностике заболеваний легких у человека. Для повышения качества диагностики система интеллектуального анализа была дополнена процедурами предпроцессорной обработки цифровых изображений. Обучение сети проводилось с использованием снимков человеческих легких, полученных на флюорографическом аппарате, а также рентгеновских снимков из открытых источников. Было показано, что дополнительное обучение предварительно обученных глубоких нейронных сетей позволяет с высокой точностью выполнять задачи классификации объектов.

Отметим, что благодаря своей универсальности результаты применения сети ResNet50 остаются стабильными и не зависят от каждого конкретного случая. Особенно высокую точность сеть демонстрирует при классификации патологий COVID-19. Продолжение данной работы заключается в проектировании и разработке нейронной сети с учетом преимуществ предварительно обученных сетей для повышения точности распознавания объектов. Другими направлениями развития являются модификация алгоритмов предварительной обработки для улучшения качества снимков, а также расширение набора диагностических случаев в системе интеллектуального анализа для более точной классификации цифровых изображений при постановке диагнозов.

Кроме того, интеграция современных методов машинного обучения и компьютерного зрения с традиционными подходами к обработке медицинских изображений открывает новые перспективы для развития медицинской диагностики. В частности, использование адаптивных алгоритмов и методов глубокого обучения может значительно повысить оперативность и точность

диагностики, что в свою очередь способствует более своевременному и эффективному лечению пациентов. Разработанная система, обладая высокой гибкостью и адаптируемостью, может быть легко интегрирована в существующие медицинские информационные системы, что делает ее перспективной для широкого клинического применения.

Перспективы дальнейшего развития данной работы включают в себя несколько ключевых направлений:

улучшение алгоритмов предварительной обработки изображений: разработка и внедрение более эффективных алгоритмов, которые могут улучшить качество изображений перед их анализом, что повысит точность и надежность диагностики;

расширение набора диагностических случаев: включение большего количества различных патологий в обучающие данные для создания более универсальной системы, способной точно диагностировать широкий спектр заболеваний легких;

интеграция с медицинскими информационными системами: разработка интерфейсов и протоколов для бесшовной интеграции разработанной системы с существующими медицинскими информационными системами, что упростит внедрение технологии в клиническую практику;

разработка адаптивных алгоритмов обучения: создание алгоритмов, которые могут адаптироваться к новым данным и улучшаться со временем, что позволит системе постоянно повышать свою точность и эффективность;

реализация в мобильных и облачных платформах: адаптация системы для использования на мобильных устройствах и в облачных платформах, что позволит расширить доступ к передовым диагностическим инструментам и улучшить их доступность для медицинских учреждений по всему миру;

проведение клинических испытаний: организация и проведение масштабных клинических испытаний для оценки эффективности системы в реальных условиях, что поможет подтвердить ее практическую ценность и выявить возможные области для улучшения;

обучение и поддержка медицинского персонала: разработка обучающих программ и материалов для медицинского персонала, что позволит врачам и медицинским работникам эффективно использовать новую технологию в повседневной практике;

этические и правовые аспекты: исследование этических и правовых вопросов, связанных с использованием искусственного интеллекта в медицинской диагностике, включая защиту данных пациентов и обеспечение прозрачности алгоритмов.

Развитие этих направлений не только повысит качество диагностики заболеваний легких, но и внесет значительный вклад в общую область медицинских технологий, улучшая результаты лечения и качество жизни пациентов.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Mothkur, R. Classification of lung cancer using lightweight deep neural networks / R. Mothkur, B.N. Veerappa. – *Procedia computer science* – 2023. – 218 с.
2. Ivanenko, M. Image reconstruction using supervised learning in wearable electrical impedance tomography of the thorax / M. Ivanenko, W.T. Smolik, D. Wanta, M. Midura, P. Wróblewski, X. Yan. Hou. – *Sensors*, 2023. – 21 с.
3. Truszkiewicz, A. Neural network in the analysis of the mr signal as an image segmentation tool for the determination of T1 and T2 relaxation times with application to cancer cell culture / A. Truszkiewicz, D. Bartusik-Aebisher, L. Wojtas, G.Cieslar, A. Kawczyk-Krupka, D. Aebisher. – *International journal molecular sciences*. – 2023, Vol. 24. № 2, P. 18 с.
4. Alsheikhy, A.A. CAD system for lung cancer detection using hybrid deep learning techniques / A.A. Alsheikhy, Y. Said, T. Shawly, A. Alzahrani, H. Lahza. – *Diagnostics*, 2023. – Vol. 13. № 6, P. 20 с.
5. Yilmaz, V. S. Investigating the impact of two major programming environments on the accuracy of deep learning-based glioma detection from MRI images / V. S. Yilmaz, M. Akdag, Y. Dalveren, R.O. Doruk, A. Kara, A. Soylu. – *Diagnostics*, 2023 – Vol. 13 № 4, P. 15.
6. Салмиянов, В.О. Программный комплекс системы сегментации и мультифрактальной диагностики цифровых изображений компьютерной томографии легки. / В.О. Салмиянов, А.Г. Масловская. – *Вестник Томского государственного университета. Управление, вычислительная техника и информатика*, 2023. – № 65. – С. 105 – 115.
7. Масловская, А.Г. Алгоритмы мультифрактального вейвлет-анализа в задачах спецификации растровых изображений самоподобных структур / А.Г. Масловская, Л.С. Афанасов. – *Вестник Томского государственного университета. Управление, вычислительная техника и информатика*, 2020. – Т. 53. – С. 61 – 70.

8. Szigeti, K. Radiomics-based differentiation of lung disease models generated by polluted air based on X-ray computed tomography data / K. Szigeti, T. Szabó, C. Korom, I. Czibak, I. Horváth, D. S. Veres, Z. Gyöngyi, K. Karlinger, R. Bergmann, M. F. Pócsik, R. Budán, D. Máthé et. al. – BMC Medical Imaging, 2016. – Vol. 16. – № 1. – Art. 14. – P. 10.
9. Troshin, P.I. Multifractal parametrization in diagnosis of lungs diseases / P.I. Troshin. – International journal of pure and applied mathematics, 2015. – Vol. 105. – № 2. – P. 173 – 185 с.
10. Щетинин, Е.Ю. Компьютерная система обнаружения COVID-19 по рентгеновским снимкам легких методами глубокого обучения / Е.Ю. Щетинин, Л.А. Севастьянов. – Вестник Томского государственного университета. Управление, вычислительная техника и информатика, 2022. – № 58. – С. 97–105. doi: 10.17223/19988605/58/9
11. Xia, Y. Fractal dimension, lacunarity and succolarity analyses on CT images of reservoir rocks for permeability prediction / Y. Xia, J. Cai, E. Perfect, et. al. – Journal of Hydrology, 2019. – Vol. 579. – P. 124198 (30)
12. Gilmore, S. Lacunarity analysis: a promising method for the automated assessment of melanocytic naevi and melanoma. / S. Gilmore, R. Hofmann-Wellenhof, J. Muir, et. al. – Plos ONE, 2009. – Vol. 4. – № 10. – P. 10.
13. Appadurai, J. P. Multi-process remora enhanced hyperparameters of convolutional neural network for lung cancer prediction. / J. P Appadurai, B.P., Kavin, W.C. Lai. – Biomedicines, 2023. – Vol. 11. – № 3. – P. 18.
14. Aykanat, M. Classification of lung sounds using convolutional neural networks. / M. Aykanat, Ö. Kılıç, B. Kurt, S. Saryal. – EURASIP journal on image and video processing, 2017. – № 65 – P. 9.
15. Gonzalez, R. C., Digital Image Processing Using MATLAB / R. C. Woods, S. L. Eddins. – Pearson Prentice Hall, 2018. – 845 с.
16. Sonka, M., Image Processing, Analysis, and Machine Vision. Cengage Learning / V. Hlavac, R. Boyle. – Stanford: Cengage Learning, 2015. – 930 с.

17. Scott, E.U. Digital Image Processing and Analysis, 4th Edition / E. U. – CRC Press, 2022. – 1123 с.
18. Esteva, A. Dermatologist-level classification of skin cancer with deep neural networks / B. Kuprel, R. A. Novoa, K. Justin, S. M Swetter, H. M. Blau, S. Thrun. – Nature, 2017. – 115-118 с.
19. Mavroforou, A. Ethical and legal aspects on the use of images and photographs in medical teaching and publication / G. Antoniou, AD. Giannoukas. – Int Angiol 2010. – С. 376-9.
20. Труфанов, Г.Е. Ультразвуковая диагностика заболеваний органов брюшной полости / Г.Е. Труфанов, В. В. Рязанов. – Москва: ГЭОТАР-Медиа, 2016. – 240 с.
21. Хофер, М., Компьютерная томография / М. Хофер. – М.: Мед.лит, 2008. – 224 с.
22. Братцева, А.В. Магнитно-резонансная томография: справочник врача / А.В. Братцева, В.Г. Киселев. – МЕДпресс-информ, 2018. – 400 с.
23. Шарабрин, В.В. Рентгенология и радиология: Учебное пособие / В.В. Шарабрин, А.Г. Переслегин. – Москва: Медицина, 2014.
24. Корецкая, Н.М. Своевременность выявления туберкулеза легких и факторы на нее влияющие / Н.М.Корецкая, А.Н.Наркевич, Л.Г. Носова. – Acta biomedica scientifica, 2012. – С. 368-371.
25. Котляров, П.М. Многосрезовая компьютерная томография легких – новый этап развития лучевой диагностики заболеваний легких / П.М. Котляров Медицинская визуализация, 2011. – (4): 14–20
26. Каприн, А.Д. Состояние онкологической помощи населению России в 2015 году / В.В.Старинский, Г.В.Петрова. М., 2018. 236. [Kaprin A.D., Starinsky V.V., Petrova G.V. The state of oncological care for the population of Russia in 2015. Moscow. – 2018. 236. (in Russian)].
27. Бурдюк, Ю.В. Компьютерная томография в диагностике хронической обструктивной болезни легких // О.Н. Гумерова, Ю.Г. Азнабаева, Ш.З.

Загидуллин, 2013. – № 6. [Электронный ресурс]. – Режим доступа: <https://scienceEducation.ru/ru/article/view?id=10921>. – 17.11.2023.

28. Синагатулин А.А. Цифровая вейвлет-мультифрактальная диагностика рентгеновских снимков легких в ППП Matlab. / А.А. Синагатулин, А.Г. Масловская. – Молодежь XXI века: шаг в будущее: материалы XXIV региональной научно-практической конференции (18 мая 2023 г., Благовещенск). – Благовещенск: типография АмГУ, 2023. – Т. 4. – 179 с.

29. Справочный центр Matlab = Matlab Help Center Library [Электронный ресурс]. – Режим доступа: https://www.mathworks.com/help/matlab/creating_plots/create-line-plot-with-markers.html. – 17.09.2024.

30. Открытая документация ЦИТМ экспонента = Open ocumentation of the CITM exponenta [Электронный ресурс]. – Режим доступа: <https://docs.exponenta.ru/r2021a/matlab/index.html>. – 16.12.2010.

31. Ахмед, С.Х. Скородумов С.В. Использование нейросетевых подходов в диагностировании заболеваний. / С.Х. Ахмед, С.В. Скородумов. – Моделирование и анализ данных, 2020. – Т. 10. – № 2. – С. 49 – 61.

32. Molčan S. Classification of red blood cells using time-distributed convolutional neural networks from simulated videos. / S.Molčan, M. Smiešková, H. Bachratý, K. Bachratá, P. Novotný. – Applied sciences, 2023. – Vol. 13. – № 13. – P. 15.

33. Hossain M. B. Transfer learning with fine-tuned deep CNN ResNet50 model for classifying COVID-19 from chest X-ray images / M. B. Hossain, S. M. Hasan Sazzad Iqbal, M. M. Islam, M. N. Akhtar, I. H. Sarker. – Informatics in medicine unlocked, 2022. – Vol. 30. – P. 10.

34. Синагатулин, А.А. Система программно-аналитической нейросетевой диагностики морфологических характеристик рентгеновских снимков легких, реализованная в среде MATLAB / В кн.: «Молодежь XXI века: шаг в будущее»: сборник материалов XXV региональной научной-практической конференции. – Благовещенск. 2024. (в печати)

35. База данных рентгенографии Covid-19 (победитель премии сообщества Kaggle за набор данных о COVID-19 = Covid-19 radiography database (Winner of the COVID-19 Dataset Award by Kaggle Community) [Электронный ресурс]. – Режим доступа: <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>. – 02.02.2023.

36. Салмиянов В.О. Система нейросетевой диагностики морфологических характеристик рентгеновских снимков легких: Реализация на платформе matlab. В.О. Салмиянов, А.А. Синагатулин, А.Г. Масловская – Информатика и системы управления, № 2 (80)2024, стр. 97-109.

ПРИЛОЖЕНИЕ А

```
% Загрузка изображения
L = imread('cameraman.tif');
% Отображение изображения
figure;
imshow(L);
title('Выберите область для обрезки изображения');
% Интерактивное кадрирование изображения
croppedImage = imcrop;
% Отображение обрезанного изображения
figure;
imshow(croppedImage);
title('Обрезанное изображение');
Работа функции imhist
L=imread('man.jpg');
figure, imshow(L);
figure, imhist(L);
```

Работа функции impixel

```
% Интерфейс для выбора пикселей с изображения
[x, y, pixelValues] = impixel;
% Отображение выбранных пикселей и их значений
disp('Координаты и значения выбранных пикселей:');
for i = 1:size(pixelValues, 1)
fprintf('Пиксель [%d, %d]: R = %d, G = %d, B = %d\n', x(i), y(i), pixelValues(i, 1),
pixelValues(i, 2), pixelValues(i, 3));
end
```

% Отображение значений пикселей в командном окне

```
disp('Значения выбранных пикселей:');
```

```
disp(pixelValues);
```

Листинг 5 – Работа функции histeq

```
L=imread('cameraman.tif');
```

```
figure, imshow(L);
```

```
L1=histeq(L);
```

```
Figure, imshow(L1);
```

Работа функции fspecial

```
h=fspecial('log', 3, .5);
```

```
L1 = imfilter(L,h,'replicate');
```

```
figure, imshow(L1);
```

Листинг 9 – Работа функции qtdecomp

```
I = imread('man.jpg');
```

```

S = qtdecomp(I,27);
blocks = repmat(uint8(0),size(S));
for dim = [512 256 128 64 32 16 8 4 2 1];
numblocks = length(find(S==dim));
if (numblocks > 0)
values = repmat(uint8(1),[dim dim numblocks]);
values(2:dim,2:dim,:) = 0;
blocks = qtsetblk(blocks,S,dim,values);
end
end
blocks(end,1:end) = 1;
blocks(1:end,end) = 1;
imshow(I), figure, imshow(blocks,[])

```

Работа функции edge

```

clear;
I = imread('man.jpg');
BW1=edge(I,'sobel');
figure,imshow(BW1);title('sobel');
BW2=edge(I,'prewitt');
figure,imshow(BW2);title('prewitt');
BW3=edge(I,'roberts');
figure,imshow(BW3);title('roberts');
BW4=edge(I,'log');
figure,imshow(BW4);title('log');
BW5=edge(I,'zerocross');
figure,imshow(BW5);title('zerocross');
BW6=edge(I,'canny');
figure,imshow(BW6);title('canny');

```

Работа функции roicolor

```

I = imread('man.jpg');
figure, imshow(I);
BW = roicolor(I,128,255);
imshow(I);
figure, imshow(BW);

```

ПРИЛОЖЕНИЕ Б

```
function varargout = MainForm(varargin)
gui_Singleton = 1;
gui_State = struct('gui_Name',    mfilename, ...
    'gui_Singleton', gui_Singleton, ...
    'gui_OpeningFcn', @MainForm_OpeningFcn, ...
    'gui_OutputFcn', @MainForm_OutputFcn, ...
    'gui_LayoutFcn', [], ...
    'gui_Callback', []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargout
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
function InitAxes(handles)
clc;
axes(handles.axes1); cla reset;
set(handles.axes1, 'XTick', [], 'YTick', [], ...
    'XTickLabel', '', 'YTickLabel', '', 'Color', [0.7020 0.7804 1.0000], 'Box', 'On');
axes(handles.axes2); cla reset;
set(handles.axes2, 'XTick', [], 'YTick', [], ...
    'XTickLabel', '', 'YTickLabel', '', 'Color', [0.7020 0.7804 1.0000], 'Box', 'On');

function filePath = OpenFile(imgfilePath)
```

```

if nargin < 1
    imgfilePath = fullfile(pwd, 'images/test.jpg');
end

[filename, pathname, ~] = uigetfile( ...
    { '*.jpg','All jpg Files';...
      '*.png','All png Files';...
      '*.*', 'All Files (*.*)'}, ...
    'Select a File', ...
    'MultiSelect', 'off', ...
    imgfilePath);
filePath = 0;
if isequal(filename, 0) || isequal(pathname, 0)
    return;
end
filePath = fullfile(pathname, filename);
function MainForm_OpeningFcn(hObject, eventdata, handles, varargin)
handles.output = hObject;
InitAxes(handles);
handles.I = 0;
handles.J = 0;
handles.bw_direct = 0;
handles.bw_poly = 0;
handles.bw__kittler = 0;
handles.bw_temp = 0;
guidata(hObject, handles);
function varargout = MainForm_OutputFcn(hObject, eventdata, handles)
varargout{1} = handles.output;
function pushbutton1_Callback(hObject, eventdata, handles)
filePath = OpenFile();

```

```

if isequal(filePath, 0)
    return;
end
Img = imread(filePath);
if ndims(Img) == 3
    I = rgb2gray(Img);
else
    I = Img;
end
axes(handles.axes1);
imshow(I, []);
title('Original Image');
handles.I = I;
guidata(hObject, handles);
function pushbutton2_Callback(hObject, eventdata, handles)
if isequal(handles.I, 0)
    return;
end
bw_direct = im2bw(handles.I, graythresh(handles.I));
axes(handles.axes2);
imshow(bw_direct, []);
title('Direct Binarization');
handles.bw_direct = bw_direct;
guidata(hObject, handles);
function pushbutton3_Callback(hObject, eventdata, handles)
if isequal(handles.bw_direct, 0)
    return;
end
c = [1524 1390 1454 1548 1652 1738 1725 1673 1524];
r = [1756 1909 2037 2055 1997 1863 1824 1787 1756];

```

```

bw_poly = roipoly(handles.bw_direct, c, r);
axes(handles.axes2);
imshow(handles.I, []);
hold on;
plot(c, r, 'r-', 'LineWidth', 2);
hold off;
title('Polygonal Selection in Binary Image');
handles.bw_poly = bw_poly;
guidata(hObject, handles);
function pushbutton4_Callback(hObject, eventdata, handles)
if isequal(handles.bw_poly, 0)
    return;
end
IE = mat2gray(handles.I);
IE = imadjust(IE, [0.532 0.72], [0 1]);
IE = im2uint8(mat2gray(IE));
I = im2uint8(mat2gray(handles.I));
axes(handles.axes2);
imshow(IE, []);
title('Enhanced and Adjusted Image');
figure;
subplot(2, 2, 1); imshow(I); title('Original Image');
subplot(2, 2, 2); imshow(IE); title('Enhanced Image');
subplot(2, 2, 3); imhist(I); title('Histogram of Original Image');
subplot(2, 2, 4); imhist(IE); title('Histogram of Enhanced Image');
JE = IE;
JE(handles.bw_poly) = 255;
handles.JE = JE;
guidata(hObject, handles);
function pushbutton5_Callback(hObject, eventdata, handles)

```

```

if isequal(handles.JE, 0)
    return;
end
J = handles.JE;
[counts, gray_style] = imhist(J);
gray_level = length(gray_style);
gray_probability = counts ./ sum(counts);
gray_mean = gray_style' * gray_probability;
gray_vector = zeros(gray_level, 1);
w = gray_probability(1);
mean_k = 0;
gray_vector(1) = realmax;
ks = gray_level-1;
for k = 1 : ks
    w = w + gray_probability(k+1);
    mean_k = mean_k + k * gray_probability(k+1);
    if (w < eps) || (w > 1-eps)
        gray_vector(k+1) = realmax;
    else
        mean_k1 = mean_k / w;
        mean_k2 = (gray_mean-mean_k) / (1-w);
        var_k1 = (((0 : k)'-mean_k1).^2)' * gray_probability(1 : k+1);
        var_k1 = var_k1 / w;
        var_k2 = (((k+1 : ks)'-mean_k2).^2)' * gray_probability(k+2 : ks+1);
        var_k2 = var_k2 / (1-w);
    if var_k1 > eps && var_k2 > eps
        gray_vector(k+1) = 1+w * log(var_k1)+(1-w) * log(var_k2)-2*w*log(w)-2*(1-
w)*log(1-w);
    else
        gray_vector(k+1) = realmax;
    end
end

```

```

end
end
end
min_gray_index = find(gray_vector == min(gray_vector));
min_gray_index = mean(min_gray_index);
threshold_kittler = (min_gray_index-1)/ks;
bw__kittler = im2bw(J, threshold_kittler)
axes(handles.axes2);
imshow(bw__kittler, []);
title('Kittler\'s Thresholding');
handles.bw__kittler = bw__kittler;
guidata(hObject, handles);
function pushbutton6_Callback(hObject, eventdata, handles)
if isequal(handles.bw__kittler, 0)
    return;
end
bw_temp = handles.bw__kittler;
bw_temp = ~bw_temp;
bw_temp = imfill(bw_temp, 'holes');
bw_temp = imclose(bw_temp, strel('disk', 5));
bw_temp = imclearborder(bw_temp);
[L, ~] = bwlabel(bw_temp);
stats = regionprops(L);
Ar = cat(1, stats.Area);
[~, ind] = sort(Ar, 'descend');
bw_temp(L ~= ind(1) & L ~= ind(2)) = 0;
bw_temp = imclose(bw_temp, strel('disk',20));
bw_temp = imfill(bw_temp, 'holes');
bw_temp = imclose(bw_temp, strel('disk',20));
bw_temp = imfill(bw_temp, 'holes');

```

```

axes(handles.axes2);
imshow(bw_temp, []);
title('Processed Binary Image');
handles.bw_temp = bw_temp;
guidata(hObject, handles);
function pushbutton7_Callback(hObject, eventdata, handles)
if isequal(handles.bw_temp, 0)
    return;
end
ed = bwboundaries(handles.bw_temp);
axes(handles.axes2);
imshow(handles.I, []); hold on;
for k = 1 : length(ed)
    boundary = ed{k};
    plot(boundary(:,2), boundary(:,1), 'g', 'LineWidth', 2);
end
hold off;
title('Detected Boundaries in Image');
function pushbutton9_Callback(hObject, eventdata, handles)
msgbox('Launching model_viz.m. Please wait...', 'Information', 'help');
programPath = '/Users/imac/Desktop/Example Project/model_viz.m';
if exist(programPath, 'file') ~= 2
    msgbox('File model_viz.m not found.', 'Error', 'error');
    return;
end
try
    tic;
    run(programPath);
    elapsedTime = toc;

```

```

    successMessage = sprintf('Program successfully launched.\nElapsed Time: %.2f
seconds', elapsedTime);
    msgbox(successMessage, 'Information', 'help');
catch
    msgbox('Failed to launch the program.', 'Error', 'error');
end
function pushbutton8_Callback(hObject, eventdata, handles)
choice = questdlg('Are you sure you want to exit?', ...
    'Confirmation', ...
    'Yes','No','No');
switch choice
    case 'Yes'
        close all;
    case 'No'
        return;
end
function pushbutton10_Callback(hObject, eventdata, handles)
if isequal(handles.I, 0)
    return;
end
invertedImage = imcomplement(handles.I);
axes(handles.axes2);
imshow(invertedImage, []);
title('Inverted Image');
handles.invertedImage = invertedImage;
guidata(hObject, handles);
function pushbutton11_Callback(hObject, eventdata, handles)
if isequal(handles.invertedImage, 0)
    msgbox('No inverted image to save. Please generate an inverted image first.',
'Warning', 'warn');

```

```
    return;
end
selectedFolder = uigetdir('', 'Select a folder to save the inverted image');
if isequal(selectedFolder, 0)
    return;
end
try
    fileName = 'inverted_image.png';
    fullFilePath = fullfile(selectedFolder, fileName);
    imwrite(handles.invertedImage, fullFilePath);
    successMessage = sprintf('Inverted image saved successfully:\n%s', fullFilePath);
    msgbox(successMessage, 'Information', 'help');
catch
    msgbox('Failed to save the inverted image.', 'Error', 'error');
end
```