

Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Воронежский государственный университет»

На правах рукописи



Руденко Андрей Владимирович

Алгоритмы обработки и анализа изображений для интеллектуальной системы
поддержки принятия решений в урологии

Специальность: 2.3.8. Информатика и информационные процессы

Диссертация
на соискание ученой степени кандидата
технических наук

Научный руководитель
доктор технических наук, доцент
Каширина Ирина Леонидовна

Воронеж – 2025 г.

Оглавление

Введение.....	5
Глава 1 Исследование применения инструментов анализа изображений в медицинских информационных системах и системах поддержки принятия врачебных решений в урологии	13
1.1 Современное состояние применения медицинских информационных систем и систем поддержки принятия врачебных решений в различных областях медицины	13
1.1.1 Общие сведения о информационных медицинских системах и системах поддержки принятия врачебных решений.....	13
1.1.2 Исследование опыта применения инструментов компьютерного зрения для анализа медицинских изображений	25
1.1.3 Анализ опыта применения нечеткой логики в МИС и СППВР	30
1.2 Обзор современных инструментов компьютерного зрения для анализа медицинских изображений.....	36
1.2.1 Анализ медицинских изображений с помощью сегментации.....	36
1.2.2 Анализ медицинских изображений с помощью классификации	38
1.2.3 Поиск объектов на медицинских изображениях с применением детектирования	39
1.3 Применение искусственных нейронных сетей для поиска объектов на медицинских изображениях	42
1.3.1 Исследование архитектур искусственных нейронных сетей для анализа медицинских изображений.....	42
1.3.2 Критерии оценки качества определения объектов на МИ с применением нейросетей	47
Выводы первой главы	50
Глава 2 Разработка метода оценки результатов анализа медицинских изображений внутренних органов человека с применением инструментов компьютерного зрения.....	53

2.1 Оценка эффективности обучения нейронной сети и качества распознавания объектов заданных классов на медицинских изображениях нейросетью YOLO ..	53
2.1.1 Разработка процедуры создания обучающего датасета	54
2.1.2 Анализ результатов обучения нейросети.....	57
2.2 Разработка метрик оценки качества обнаружения и классификации нейросетями объектов на медицинских изображениях.....	63
2.3 Разработка алгоритма нечеткой оценки результатов определения объектов на медицинских изображениях	68
2.4 Оценка качества определения объектов нейросетью на изображениях КТ.....	75
Выводы второй главы.....	77
Глава 3 Разработка процедуры трехмерной сборки объектов, алгоритма расчета параметров и визуализации найденных объектов по результатам детектирования на медицинских изображениях	78
3.1 Разработка алгоритма трехмерной сборки объектов почек и камней.....	78
3.2 Разработка алгоритма расчета параметров объектов камней	84
3.3 Разработка алгоритма трехмерной визуализации объектов почек и камней	86
Выводы третьей главы	88
Глава 4 Разработка системы поддержки принятия врачебных решений в урологии с применением компьютерного зрения в урологии	89
4.1 Разработка требований к системе поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения	89
4.2 Разработка алгоритма поддержки принятия врачебных решений выбору категории режима работы лазера для проведения процедуры лазерной литотрипсии.....	91
4.3 Проектирование архитектуры системы поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения..	102
4.4 Разработка программных модулей системы поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения..	109
Выводы четвертой главы	135
Заключение	137

Список сокращений и условных обозначений	140
Список литературы.....	141
Приложение А Диаграмма прецедентов.....	157
Приложение Б Диаграмма последовательности.....	158
Приложение В Описание работы системы.....	159
Приложение Г Свидетельства о регистрации программ для ЭВМ.....	182
Приложение Д Протокол тестирования.....	185
Приложение Е Акты внедрения	187

Введение

Актуальность. Стремительное развитие информационных технологий открывает новые возможности для обработки и анализа больших массивов данных, в том числе в медицинской сфере, где ежедневно генерируются терабайты информации в виде магнитно-резонансных (МРТ) и компьютерно-томографических (КТ) изображений. Современные алгоритмы искусственного интеллекта способны эффективно обрабатывать эти данные, по скорости значительно превосходя традиционные методы ручного анализа. В задачах распознавания паттернов и аномалий на медицинских изображениях (МИ) особенно впечатляющие результаты демонстрируют искусственные нейронные сети (ИНС). Интеллектуальные системы поддержки принятия решений на основе ИНС способны анализировать огромные массивы медицинских данных в режиме реального времени, предоставляя врачам дополнительный инструмент для повышения точности диагностики. Однако для полноценного внедрения таких систем в клиническую практику критически важна их объяснимость, то есть способность предоставлять интерпретируемые результаты, подтвержденные достоверными метриками точности. В этой связи совершенствование алгоритмов обработки и анализа медицинских изображений, направленное на развитие методов визуализации работы моделей и повышение надежности их оценок представляет собой важную и актуальную научно-практическую задачу.

Степень разработанности темы диссертации. Проблемы анализа медицинских изображений с применением различных инструментов, в том числе нейронных сетей, рассмотрены в работах С.Р. Абульханова, В.А. Ковалева, Н.А. Щукиной, Д.А. Коблякова, А.Ю. Мягкова, Е.А. Гусева, С. А. Филиста, М.А. Горелова, Ю.В. Бруттана. Опыт анализа медицинских изображений в медицинских информационных системах, а также опыт разработки систем поддержки принятия врачебных решений с применением технологий компьютерного зрения представлены в работах О.Ю. Ребровой, В.О. Новицкого, А.А. Прановича, В.Л. Малых, А.М. Рюмина. Однако, несмотря на накопленный опыт отечественных и зарубежных исследователей, остается ряд нерешенных проблем, из-за которых автоматизированные системы анализа МРТ и КТ-изображений остаются недостаточно внедренными в клиническую практику. Во-первых, даже при высокой

точности на обучающих данных, алгоритмы сегментации и детектирования могут ошибаться из-за сложной анатомии объектов, вариабельности патологий и неоднозначности интерпретации результатов. Классические метрики качества моделей не учитывают анатомическую реалистичность обнаруженных объектов, что снижает надежность систем в реальных клинических сценариях. Во-вторых, точная 3D-визуализация органов и патологий требует высококачественных аннотированных датасетов, создание которых сопряжено с высокими затратами времени и ресурсов. Поэтому важной задачей является разработка методов, объединяющих точность нейросетевой детекции с возможностями 3D-реконструкции для наглядной и интерпретируемой оценки результатов для различных анатомических органов и структур.

Целью диссертации является разработка алгоритмов автоматизированного анализа КТ-изображений на основе нейросетевых технологий и методов нечеткой логики для интеграции в системы поддержки принятия врачебных решений при обработке данных медицинской визуализации.

Для достижения поставленной цели необходимо решить следующие **задачи**:

1. Исследовать опыт применения систем компьютерного зрения в урологии, провести оценку эффективности инструментов для анализа медицинских изображений и осуществить выбор наиболее подходящего инструмента для поиска объектов на изображениях, полученных в результате КТ внутренних органов человека.

2. Разработать метрики для оценки точности, достоверности и правдоподобия результатов детектирования медицинских изображений.

3. Разработать алгоритм нечеткой оценки результатов детектирования и классификации объектов на изображениях КТ.

4. Разработать алгоритм реконструкции, расчета параметров и 3D-визуализации объектов по полученным результатам детектирования на изображениях КТ.

5. Разработать комплекс алгоритмов для системы поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения и методов нечеткой логики.

Объектом исследования является информационная система поддержки принятия врачебных решений (СППВР) в урологии.

Предметом исследования являются методы и алгоритмы компьютерного зрения для автоматизированного анализа и детектирования объектов на медицинских изображениях в системах поддержки принятия врачебных решений.

Методы исследования. При решении поставленных в диссертации задач использовались методы моделирования и проектирования информационных систем, включающие структурный и объектно-ориентированный подходы, методы применения инструментов компьютерного зрения в медицинской диагностике, методы математического моделирования и алгоритмизации процессов обработки и анализа МИ, методы нечеткой логики, нейросетевые технологии. Для оценки эффективности разработанной системы использовались методы экспериментальной проверки и статистического анализа полученных результатов.

Научная новизна исследования заключается в следующем.

В работе и разработанной системе поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения получены результаты, обладающие научной новизной:

1. Метрики оценки точности, достоверности и правдоподобия результатов нейросетевого детектирования и классификации объектов на медицинских КТ-изображениях, учитывающие достоверность локализации и классификации найденных объектов, их форму и плотностные оценки.

2. Алгоритм нечеткой оценки детектирования найденного объекта на изображениях КТ, основанный на концепции использования «облаков правдоподобия» для описания пространственного положения объектов, отличающийся комплексным использованием предложенных метрик и позволяющий учитывать неопределенность и вариабельность в расположении и форме объектов.

3. Алгоритмы трехмерной реконструкции и расчета параметров объектов, отличающиеся возможностью по результатам 2D-детектирования на медицинских изображениях выполнить расчет размеров, массы, плотности обнаруженных объектов, визуализировать их взаимное расположение.

4. Структура программного комплекса для интеграции в системы поддержки принятия врачебных решений в области урологии, обеспечивающая сквозную обработку диагностических данных – от нейросетевого анализа изображений и верификации результатов детектирования до формирования персонализированных рекомендаций по подбору оптимизированных параметров лазерного воздействия с использованием нечеткой логики.

Теоретическая значимость. Теоретическая значимость заключается в разработке алгоритма нечеткой оценки результатов детектирования объектов на МИ, учитывающего специфику предметной области.

Практическая значимость состоит в создании системы поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения.

Реализация и внедрение результатов работы. Материалы диссертации в форме СППВР используются в работе Автономной некоммерческой медицинской организации «Ставропольский краевой клинический консультативно-диагностический центр», г. Ставрополь. Теоретические результаты диссертационной работы внедрены в учебный процесс ФГАОУ ВО Крымский федеральный университет имени В.И. Вернадского, а также используются в Медицинском институте им. С.И. Георгиевского для подготовки специалистов на клинической кафедре в поликлинике Многопрофильной Клинической Больницы Святителя Луки.

Достоверность полученных научных результатов подтверждается тестированием разработанной системы поддержки принятия врачебных решений совместно со специалистами Клинического медицинского многопрофильного центра имени Святителя Луки г. Симферополь, который обладает современной базой радиологии и уникальными методиками лечения МКБ.

Соответствие паспорту специальности. Диссертация подготовлена в соответствии с паспортом научной специальности 2.3.8. Информатика и информационные процессы и охватывает следующие области исследования, входящие в эту специальность:

7. Разработка методов обработки, группировки и аннотирования информации, в том числе, извлеченной из сети интернет, для систем поддержки принятия решений, интеллектуального поиска, анализа.

13. Разработка и применение методов распознавания образов, кластерного анализа, нейросетевых и нечетких технологий, решающих правил, мягких вычислений при анализе разнородной информации в базах данных.

16. Автоматизированные информационные системы, ресурсы и технологии по областям применения (научные, технические, экономические, образовательные, гуманитарные сферы деятельности), форматам обрабатываемой, хранимой информации. Системы принятия групповых решений, системы проектирования объектов и процессов, экспертные системы и др.

Основные положения, выносимые на защиту:

1. Введенные метрики оценки точности детектирования DP , достоверности объекта OR и правдоподобия объекта OV обеспечивают комплексный анализ результатов детектирования, поскольку учитывают не только точность найденных границ, но и правдоподобие расположения объекта в контексте медицинского изображения, а также оценку плотности объекта для определения степени корректности его идентификации.

2. Для определения качества детектирования объектов на медицинских КТ - изображениях целесообразно использовать предложенный алгоритм нечеткой оценки, позволяющий, в среднем, на 30% снизить долю ложноположительных результатов детектирования, эффективность которого обеспечивается использованием введенных метрик и применением концепции «облака правдоподобия».

3. Предлагаемый алгоритм 3D-реконструкции и расчета параметров объектов позволяет определять их геометрические и физические характеристики (размеры,

объем, плотность), а также визуализировать их пространственное расположение, основываясь на результатах нейросетевой детекции 2D срезов и данных матрицы интенсивностей по шкале Хаунсфилда.

4. Разработанный алгоритм определения режимов работы лазерной установки на основе анализа найденных характеристик и пространственного расположения почек и камней формирует рекомендации по подбору параметров лазерного излучения в соответствии с геометрическими и физическими свойствами объектов.

Апробация результатов работы. Основные результаты диссертации докладывались и обсуждались на международных конференциях: XXV Международная конференция им. Э.К. Алгазинова «Информатика: проблемы, методы, технологии» (IPMT), 12-13 февраля 2025, ВГУ, г. Воронеж; Международная научно-практическая конференция «Искусственный интеллект – технологии развития человека 2024» (AITHD 2024), 25-28 сентября 2024, пгт. Гурзуф; Международная научно-практическая конференция «Искусственный интеллект – технологии развития человека 2023» «Таврида – ИИ 2023» (AITHD 2023), 13-16 сентября 2023 г. Гурзуф; Международная научно-практическая конференция «Искусственный интеллект – технологии развития человека 2022» «Таврида – ИИ 2022» (AITHD 2022), 13-17 июля 2022 г. Гурзуф, Россия; III Международная конференция по нейронным сетям и нейротехнологиям (NeuroNT'2022), 16 июня 2022, г. Санкт-Петербург, СПбГЭТУ «ЛЭТИ»; XXIV Международная конференция по мягким вычислениям и измерениям, 26 – 28 мая 2021, г. Санкт-Петербург, СПбГЭТУ «ЛЭТИ».

Публикации. По материалам диссертации опубликовано 12 работ, в том числе 4 статьи в рецензируемых научных изданиях, рекомендованных ВАК для специальности 2.3.8, 5 работ опубликованы в трудах Международных конференций, получено 3 свидетельства на программы для ЭВМ.

Связь с государственными программами и НИР. Исследования выполнены при финансовой поддержке ФГБУ «Фонд содействия развитию малых форм предприятий в научно-технической сфере», программа «Старт», конкурс

«Старт-Искусственный интеллект-1» (I очередь), заявка С1ИИ-112266, договор № 27ГС1ИИС12-D7/71365.

Структура и объем работы. Диссертационная работа состоит из введения, четырех глав, заключения, списка сокращений, списка литературы и семи приложений. Основная часть работы составляет 156 страниц, включая 50 рисунков, 10 таблиц; список литературы из 114 наименований.

Краткое содержание работы.

Во **введении** описано состояние рассматриваемой проблемы и обоснована актуальность темы диссертации. Сформулированы цели и задачи исследования, новизна полученных результатов и защищаемые положения.

В **первой главе** проведено исследование современного состояния применения информационных систем и систем поддержки принятия врачебных решений, инструментов компьютерного зрения, а также архитектур искусственных нейронных сетей для анализа медицинских изображений в урологии. Определены проблемы, требующие дальнейшего решения, такие как неэффективность существующих метрик оценки, сложности, связанные с подготовкой и аннотированием обучающих наборов данных, и недостаточное распространение систем поддержки принятия врачебных решений на основе компьютерного зрения во многих специализированных медицинских областях. Для определения объектов почек и камней на МИ методы сегментации, в том числе с применением нейросетевых технологий не принесли желаемого результата, поэтому для решения данной задачи было определено детектирование с помощью нейронной сети архитектуры YOLOv5.

Во **второй главе** описана реализация алгоритма обучения нейронной сети YOLO для обнаружения объектов заданных классов на МИ, и предлагается метод оценки результатов детектирования и классификации объектов на МИ. Для решения проблемы оценки качества полученных результатов детектирования объектов на МИ с помощью нейросети YOLOv5 в работе предлагаются следующие метрики: точность детектирования DP (detect precision), достоверность объекта OR (object reliability) и правдоподобие объекта OV (object veracity). Предлагаемый

алгоритм оценки полученных результатов детектирования объектов на изображениях КТ использует нечеткие правила классификации. Разработанная методика оценки результатов детектирования и классификации объектов почек и камне на МИ позволила увеличить точность определяемых объектов на МИ.

В третьей главе проведена разработка алгоритма процедуры трехмерной сборки объектов почек и камней, алгоритма расчета параметров найденных объектов камней, алгоритмы 3D визуализации объектов. Разработанный алгоритм трехмерной сборки объектов почек и камней позволяет из плоских срезов КТ выполнить послойную сборку объектов. Алгоритм расчета параметров камней позволяет рассчитать линейные размеры, массу камня, его плотность. Алгоритмы трехмерной визуализации позволяют наглядно представить найденные объекты почек и камней.

В четвертой главе проведена разработка алгоритмов для системы поддержки принятия медицинских решений в области урологии. Разработан алгоритм поддержки принятия врачебного решения по выбору параметров работы лазерной установки при проведении процедуры литотрипсии (разрушения камня лазером) с применением нечеткого вывода. Проведена разработка архитектуры СППВР в урологии, выполнена программная реализация разработанных модулей системы.

В заключении подведены итоги и обобщены результаты проведенных исследований.

В приложениях приведены UML диаграммы, описание работы разработанной СППВР в урологии, свидетельства на разработанные программы для ЭВМ, протокол тестирования системы, акты внедрения результатов диссертационного исследования.

Глава 1 Исследование применения инструментов анализа изображений в медицинских информационных системах и системах поддержки принятия врачебных решений в урологии

1.1 Современное состояние применения медицинских информационных систем и систем поддержки принятия врачебных решений в различных областях медицины

1.1.1 Общие сведения о информационных медицинских системах и системах поддержки принятия врачебных решений

Медицинские информационные системы (МИС) и системы поддержки принятия врачебных решений (СППВР) — это информационные системы, помогающие врачам в клинической практике. Они используют данные пациентов, протоколы и медицинские знания для предоставления персонализированных рекомендаций и прогнозов. МИС представляют собой комплекс программно-аппаратных средств для сбора, хранения, обработки и передачи информации в здравоохранении. Ключевые компоненты МИС включают информационные ресурсы, оборудование, программное обеспечение, персонал и организационные процедуры. Основные задачи МИС — это обеспечение качественного ухода за пациентами, управления ЛПУ и информационное обеспечение системы здравоохранения [1].

Любая МИС содержит блоки для регистратуры, электронных медицинских карт, медицинской диагностики, рабочих мест персонала, поддержки принятия решений, распределения ресурсов, стандартов оказания помощи, коммуникации, назначений и управления финансами. Классификация МИС основывается на уровнях управления: оперативный (автоматизация рутинных процессов), тактический (поддержка решений на уровне отделений) и стратегический (анализ и планирование на уровне учреждения). МИС применяются на федеральном, региональном и муниципальном уровнях, включая Единую государственную информационную систему в сфере здравоохранения (ЕГИСЗ) на федеральном уровне, автоматизируя процессы в учреждениях и обеспечивая поддержку медицинского персонала [2].

Одной из более полных классификаций медицинских информационных систем является классификация, основанная на иерархическом принципе, которая отображает многоуровневую структуру отрасли здравоохранения. В здравоохранении Российской Федерации МИС применяются на различных уровнях, включая федеральный, региональный и муниципальный. На федеральном уровне функционируют системы, обеспечивающие мониторинг и управление здравоохранением на национальном уровне, такие как ЕГИСЗ. На региональном уровне МИС обеспечивают управление медицинскими учреждениями и оказанием медицинской помощи на территории субъекта Российской Федерации. На муниципальном уровне МИС автоматизируют процессы в муниципальных медицинских учреждениях, обеспечивая оперативное управление и поддержку медицинского персонала (рисунок 1.1) [3].




Рисунок 1.1 - Иерархическая структура ЕГИСЗ

Медицинские информационные системы, как и отрасль здравоохранения, подразделяются на уровни с различным функционалом. МИС базового уровня поддерживают врачей, повышая качество диагностики и лечения при дефиците времени и специалистов. МИС уровня учреждений объединяют информацию и автоматизируют деятельность ЛПУ, обеспечивая связь с системами высшего уровня. Территориальные МИС создают программные комплексы для управления

медицинскими службами на конкретной территории. Информационные системы федерального уровня объединяют региональные МИС для обеспечения государственного здравоохранения. МИС базового уровня включают информационно-справочные и консультативно-диагностические системы. Приборно-компьютерные системы отслеживают физиологические параметры пациентов. Автоматизированные рабочие места (АРМ) поддерживают врачей при принятии решений. Консультативные центры используют МИС для объединения профильных отделений и диагностики. Базы данных МИС хранят сведения о пациентах, персонале и динамике состояния для быстрого поиска и анализа [4]-[9].

Скрининговые системы являются приоритетом компьютеризации здравоохранения, обеспечивая мониторинг населения и выявление нуждающихся в помощи. Информационные системы ЛПУ объединяют несколько МИС для создания единой системы медицинского учреждения. МИС федерального и территориального уровней различаются масштабом применения. ИС органов здравоохранения выполняют административно-управленческие и организационно-статистические функции, а статические МИС обрабатывают первичную медицинскую информацию. МИС отраслевых служб обеспечивают специализированную информационную поддержку (например, ЧС, онкология). Медико-технологические информационные системы поддерживают деятельность специализированных медицинских служб [10]-[11].

На рисунке 1.2 представлена схема примерной классификации медицинских информационных систем [12].

Системы поддержки принятия врачебных решений (СППВР) являются важным компонентом МИС, ориентированным на повышение качества и эффективности медицинской помощи. СППВР обеспечивают врачам доступ к актуальной клинической информации, аналитическим инструментам и рекомендациям, основанным на данных и экспертных знаниях. Назначение СППВР заключается в предоставлении врачам поддержки при диагностике, выборе методов лечения, оценке рисков и планировании медицинской помощи.




Рисунок 1.2 - Классификация МИС

СППВР выполняют различные задачи, такие как анализ медицинских записей, интерпретация лабораторных и инструментальных данных, предсказание исходов заболеваний, оценка эффективности лечения и рекомендации по дальнейшему ведению пациента. В урологии СППВР могут включать в себя системы, использующие технологии компьютерного зрения, что позволяет автоматизировать анализ медицинских изображений, таких как рентгеновские снимки, ультразвуковые исследования. Использование таких систем способствует улучшению точности диагностики, сокращению времени принятия решений и снижению нагрузки на медицинских работников. СППВР является программным комплексом, который позволяет при помощи сбора и анализа данных оказывать

воздействие на принятие решения медицинским специалистом при диагностике, различных обследованиях, а также назначении лекарств, что повышает качество оказания медицинской помощи [13].

СППВР подразделяют на информационно-справочные и интеллектуальные. Интеллектуальные, в свою очередь, классифицируют на моделирующие и имитирующие рассуждения. Первые из них формируются на основе знаний экспертов, а вторые – на построении моделей, которые имеют различия в методах многомерного анализа данных и также используют методы машинного обучения.

Таким образом, медицинские информационные системы и системы поддержки принятия врачебных решений играют важную роль в современном здравоохранении, обеспечивая эффективное управление медицинскими процессами и повышение качества медицинской помощи [14].

Проблемы разработки, внедрения и использования в медицинской деятельности МИС и СППВР, опыт применения искусственного интеллекта в медицинских диагностических системах представлены в работах С.В. Фролова, А.В.Гусева, О.Ю. Ребровой, В.О. Новицкого, А.А. Прановича, В.Л. Малых.

В своем исследовании Фролов С.В. и другие авторы [15] анализируют современные системы поддержки принятия врачебных решений в медицине, что обусловлено возрастающим объемом медицинской информации и усложнением ее анализа. СППВР призваны помогать врачам в принятии обоснованных решений, учитывая множественные факторы. В работе рассматриваются различные типы МИС и СППВР, включая экспертные системы, использующие базы знаний и логические правила, статистические модели, анализирующие большие массивы данных, системы на основе машинного обучения, способные к самообучению и прогнозированию результатов терапии. Авторы акцентируют внимание на потенциале СППВР для повышения качества медицинской помощи, а также отмечают существующие препятствия для их широкого внедрения в практику.

В рамках анализа российских источников авторы Малых В.Л. и другие исследователи [16] описывают основные препятствия, затрудняющие разработку систем поддержки принятия врачебных решений в медицине. Авторы предлагают

методы преодоления концептуальных барьеров и комплексное решение данной проблемы. СППВР определяются как инструменты для поддержки медицинских специалистов в диагностике и лечении. В работе рассматриваются три типа СППВР: системы, основанные на правилах, статистические системы и системы, использующие искусственный интеллект. Системы на основе правил используют формализованные правила, статистические системы применяют статистические методы для анализа данных и прогнозирования, а системы на основе искусственного интеллекта используют машинное обучение. Особое внимание уделяется гибридной модели СППВР, предназначенной для широкого применения в медицинской практике.

В исследовании Румовской С.Б. [17] представлен анализ систем поддержки принятия врачебных решений, акцентирующий внимание на их интеллектуальных функциях и сложностях разработки. Рассматриваются различные типы СППВР, предназначенные для диагностики, выбора лечения, мониторинга и обучения врачей. В работе описаны подходы к разработке СППВР, включая использование правил, статистических методов, нейронных сетей и искусственного интеллекта. На основе проведенного анализа автором рекомендовано применение современных методов искусственного интеллекта, разработка интуитивно понятных интерфейсов, учет специфики медицинских дисциплин и создание полноценных инструментов для поддержки принятия врачебных решений.

В работе Рюмина А.М. [18] исследованы перспективные направления развития систем поддержки принятия врачебных решений в клинической медицине. Автор обосновывает важность СППВР для повышения качества медицинской помощи и эффективности лечения, что снижает риск врачебных ошибок. Обзор автором существующих типов СППВР (системы на основе правил, статистические и системы искусственного интеллекта) дополняется анализом перспективных направлений - интеграция с МИС, использование анализа больших данных с применением ИИ для повышения точности СППВР, разработка персонализированных систем, применение виртуальной и дополненной реальности

для наглядности, и адаптация СППВР к специфике различных медицинских областей.

Анализируя опыт применения СППВР в медицине, можно сделать вывод о том, что СППВР играют все более важную роль в современной медицине. СППВР становятся необходимым инструментом для повышения качества медицинской помощи, снижения риска ошибок и улучшения эффективности лечения. Несмотря на многообещающий потенциал, имеется ряд препятствий, затрудняющих широкое внедрение СППВР в медицинскую практику, включая концептуальные барьеры, необходимость разработки удобных интерфейсов и адаптации к специфике различных медицинских дисциплин.

Помимо исследований проблем проектирования и внедрения в практическую медицину МИС и СППВР важным моментом являются исследования применения искусственного интеллекта в данных системах.

В работе авторов А.А. Литвина и др. [19] представлен обширный обзор применения ИИ в различных областях медицины, подчеркивающий его революционное влияние на повышение точности диагностики, эффективности лечения и улучшение ухода за пациентами. Авторы рассматривают применение ИИ в диагностике, профилактике, уходе, управлении ресурсами и выделяют ряд преимуществ использования ИИ в МИС и СППВР: повышение точности диагностики за счет раннего выявления патологий, снижение риска врачебных ошибок на основе анализа больших данных, улучшение эффективности лечения посредством персонализации, совершенствование ухода за пациентами благодаря мониторингу и индивидуальным рекомендациям, а также снижение затрат на здравоохранение за счет оптимизации процессов. Наряду с этим авторы выделили ряд трудностей, связанных с внедрением ИИ в медицине: недостаток качественных данных для обучения, проблемы с интерпретацией результатов, этические и юридические вопросы, а также дефицит квалифицированных специалистов.

В работе И. А. Шадеркина [20] проводится критический анализ применения ИИ в медицине, освещающий его недостатки и ограничения и подчеркивающий необходимость критического подхода к его внедрению. Автор, не отрицая

потенциала ИИ, акцентирует внимание на его слабых сторонах и предупреждает о рисках, связанных с некритичным использованием, таких как переоценка возможностей ИИ, снижение профессионализма врачей из-за чрезмерной зависимости от ИИ и неравномерный доступ к медицинской помощи. Автор призывает к критическому внедрению ИИ в медицине с учетом всех его ограничений и подчеркивает необходимость разработки соответствующих этических и юридических норм.

Кроме описанных выше исследований в области разработок и применения МИС И СППВР в медицине, применения ИИ в таких системах, проводятся исследования применения мягких вычислений в данной области. Так, в работе автора Кривенко М.П. [21] проведен анализ применения методов мягких вычислений в медицинской диагностике. Автор подчеркивает имеющиеся неопределенности в медицинской диагностике, обусловленные сложностью биологических систем, индивидуальными различиями пациентов, неполнотой информации и субъективностью клинического опыта. Автором рассмотрены методы мягких вычислений, такие как нечеткая логика, нейронные сети и эволюционные алгоритмы, а также их преимущества: учет неопределенности и субъективности, повышение точности диагностики за счет комплексного учета факторов, разработка персонализированных методов лечения. Приведены примеры применения мягких вычислений для диагностики, включая раннюю диагностику онкологических заболеваний и определение риска развития болезней. Автор выделяет важные направления развития применения мягких вычислений в медицине: создание более сложных моделей, интеграцию с другими медицинскими системами и разработку стандартов для применения методов мягких вычислений.

Также проводятся исследования в области применения искусственного интеллекта для диагностики и лечения различных заболеваний.

В работе авторов Пранович А.А. и др. [22] представлен обзор современных исследований по применению искусственного интеллекта (ИИ) в диагностике и лечении мочекаменной болезни. Авторы подчеркивают значимость ИИ в связи с распространенностью заболевания, сложностью диагностики и потенциалом для

улучшения результатов лечения. Рассмотрено применение ИИ для анализа медицинских изображений (рентген, КТ, УЗИ) для выявления и оценки камней, анализа больших данных для определения факторов риска и выбора оптимального лечения, планирования операций и разработки новых методов лечения (например, фокусированная ультразвуковая терапия). В работе также освещены преимущества и проблемы применения ИИ в лечении мочекаменной болезни.

В работе авторов Смирновой Т.В. и др. [23] представлены практические примеры применения искусственного интеллекта для анализа изображений компьютерной томографии (КТ). Авторы подчеркивают значение ИИ для ускорения и повышения точности анализа КТ-изображений, что способствует более быстрой и точной диагностике, планированию лечения и мониторингу терапии. В работе приводятся примеры применения ИИ: автоматическая детекция и сегментация узлов в легких, сегментация структур головного мозга, оценка степени перелома костей. Авторы подчеркивают преимущества ИИ и обозначают ключевые направления его дальнейшего развития в данной области.

В работе Левенкова К.О. и соавторов [24] исследовано применение нейронных сетей для моделирования выбора схем лечения хронического пиелонефрита и мочекаменной болезни. Авторы, учитывая сложность выбора схемы лечения, обусловленную множеством факторов, предлагают использовать нейронные сети для анализа больших данных и поиска оптимальных решений. В работе подробно описана архитектура предложенной нейронной сети, её алгоритм обучения и преимущества: учет многочисленных параметров, самообучение и адаптивность. Результаты моделирования демонстрируют высокую точность предложенной модели в построении оптимальных схем лечения, подтверждая потенциал нейронных сетей для моделирования сложных медицинских задач.

Практическое применение сервисов по поддержке принятия врачебных решений отражены в работе Галченкова А. С. и др. [25], где подчеркнута роль таких сервисов в современной медицине для принятия информированных решений о диагностике и лечении. На примере хронической болезни почек (ХБП) 5-й стадии авторы демонстрируют, как СППВР способствуют ранней диагностике

заболевания, точному определению стадии заболевания, выбору оптимального метода лечения и мониторингу его эффективности, что позволяет своевременно корректировать лечебный план. В работе также обозначены преимущества использования СППВР и направления их дальнейшего развития.

Проанализировав опыт отечественных и зарубежных исследователей применения МИС и СППВР в медицине, можно сделать следующие выводы.

Существует множество различных типов МИС и СППВР, которые применяются в медицине. Системы диагностики помогают врачам поставить диагноз, анализируя симптомы, результаты анализов и другие данные пациента. Системы прогнозирования предсказывают вероятность развития осложнений или успешность определенного лечения. Системы планирования лечения помогают врачам выбрать оптимальный план лечения с учетом индивидуальных характеристик пациента. Системы мониторинга отслеживают состояние пациента и оповещают врача о необходимости вмешательства. Применение МИС и СППВР в медицине обеспечивает улучшение качества медицинской помощи за счет более обоснованных решений и снижения ошибок, повышение точности диагностики благодаря анализу больших данных, снижение медицинских расходов путем оптимизации лечения, улучшение коммуникации врач-пациент за счет предоставления информации о состоянии и лечении, повышение эффективности работы медицинских учреждений путем автоматизации рутинных задач.

Несмотря на множество преимуществ, применение СППВР в медицине сталкивается с рядом трудностей, связанных с недостаточным объемом качественных медицинских данных, которые могут быть и недоступны в некоторых случаях, врачи могут скептически относиться к рекомендациям, выдаваемым СППВР, особенно если они не понимают принципы их работы. Применение таких систем поднимает вопросы сохранения конфиденциальности данных пациентов и ответственности за принимаемые решения.

В современном мире разработано и продолжает разрабатываться большое число медицинских информационных систем и систем поддержки принятия врачебных решений в различных направлениях медицинской деятельности. В

России активно развивается направление СППВР, создаются отечественные системы, адаптированные к особенностям российской медицины. Как российские, так и международные системы СППВР активно развиваются, предоставляя врачам доступ к передовым технологиям.

Анализ российского рынка медицинских информационных систем (МИС) позволил идентифицировать ряд наиболее распространенных платформ, используемых в медицинских учреждениях Российской Федерации. К ним относятся следующие системы.

«ArchiMed+» - универсальное программное обеспечение, предназначенное для медицинских учреждений различного масштаба. Функциональность включает автоматизированную передачу данных в Единую государственную информационную систему здравоохранения (ЕГИСЗ), инструменты телемедицины, управление ценообразованием и перечнем услуг, а также личные кабинеты пациентов (<https://archimed.pro/>).

«Дока+» - система, ориентированная на ведение клинической документации, особенностью которой является открытый исходный код, предоставляющий пользователям возможность модификации форм документов и разработки дополнительных модулей (<http://www.docaplus.com/russian/main/>).

«Инфоклиника» и «Инфодент» - программные продукты одного разработчика, предназначенные для медицинских учреждений широкого профиля и стоматологических клиник. Данные программы обеспечивают интеграцию с порталом Госуслуг, внешними лабораториями и страховыми компаниями, а также поддерживают систему уведомлений и рассылок (<https://infoclinica.ru/>).

«КМИС» (Комплексная медицинская информационная система) - платформа, обеспечивающая интеграцию с федеральными системами ЕГИСЗ и Единой цифровой картой здоровья (ЕЦКЗ), ведение статистической отчетности, электронные медицинские карты и другие функции (<https://www.kmis.ru/>).

«Webiomed» - платформа, интегрирующая систему поддержки принятия врачебных решений (СППВР) для автоматической оценки показателей здоровья

пациента и прогнозирования развития заболеваний (<https://webiomed.ru/products/webiomed-dhra/>).

«ТОП-3» - СППВР, предназначенная для оказания помощи врачам в постановке предварительного диагноза на основе анамнеза и данных медицинской карты пациента (<https://sbermed.ai/diagnostic-center/our-algorithms/top-3/>).

«MedicBK» - СППВР, обеспечивающая экспертизу электронных медицинских карт (ЭМК), выявление коморбидных пациентов и оптимизацию терапевтических и диагностических мероприятий в рамках диспансерного наблюдения (<http://medicbk.com/>).

«Panacea» - СППВР для контроля соответствия клиническим рекомендациям и стандартам оказания медицинской помощи (<https://panaceadoc.ru>).

«Medesk» — это сервис, работающий по подписке и используемый в разных регионах России и за рубежом. Ключевой особенностью сервиса является комплексный подход, включающий не только ведение электронных медицинских карт и отчётности, но и складской учёт, онлайн-платежи, а также инструменты для телемедицинских консультаций (<https://www.medesk.net/ru/>).

В отличие от него, «MEDMIS», запущенный в 2017 году (<https://www.medmis.ru/>), делает акцент на ведении электронных медицинских карт и интеграции с лабораторными информационными системами.

«МЕДИАЛОГ» - представляет собой программный комплекс, ориентированный на крупные медицинские организации, предоставляет широкий набор функций и настроек, таких как ведение электронных медицинских карт, планирование приемов пациентов, управление филиалами, складской учет и онлайн-запись (<https://medialog.ru/>).

«MEDODS» - сервис, ориентированный на работу со стоматологическими клиниками, он обеспечивает онлайн-запись клиентов, интеграцию с лабораториями, отправку SMS-уведомлений и рассылок (<https://www.medods.ru/>).

МИС «Реновацио» - предоставляет широкий набор различных функциональных модулей, назначение которых — полноценная и эффективная автоматизация медицинского учреждения (<https://rnova.ru/>).

Опыт применения медицинских информационных систем за пределами РФ подробно рассмотрен в работе Монакова Д.М. и соавторов [26]. В исследовании представлен обзор опыта применения медицинских информационных систем в европейских странах, основанный на анализе исследований, докладов и отчетов Европейского регионального бюро ВОЗ. Исследование показывает, что ведущим направлением в развитии трансграничного электронного здравоохранения являются инновационные технологии и передовые решения для усовершенствования взаимодействия медицинских систем. Выявлены общие факторы и закономерности при анализе сильных и слабых сторон технологий, а также проблем, влиявших на переход к электронному здравоохранению в европейских странах.

Проведенный анализ опыта применения медицинских информационных систем и СППВР в российских и зарубежных медицинских учреждениях [27]-[30] показал, что в настоящий момент отсутствуют системы, которые бы помогали врачу-урологу в планировании хирургического вмешательства с применением лазерной литотрипсии для удаления камней в почках при мочекаменной болезни. Поэтому существует необходимость в разработке такой системы поддержки принятия врачебных решений, которая позволила бы производить чтение медицинских данных, полученных по результатам проведения компьютерной томографии, производить поиск почек и камней на изображениях внутренних органов, определять параметры найденных камней, осуществлять визуализацию найденных объектов, выполнять расчет времени разрушения найденных камней при помощи лазерной установки, таким образом помогая врачам-клиницистам ставить диагноз мочекаменной болезни и планировать хирургические операции.

1.1.2 Исследование опыта применения инструментов компьютерного зрения для анализа медицинских изображений

Важным и интересным направлением, где возможно применение технологий и инструментов компьютерного зрения, является анализ объектов на медицинских изображениях (МИ). На сегодняшний день анализ МИ и поиск объектов на них

широко применяется в медицинской диагностике – от анализа крови до магнитно-резонансной томографии. Анализ МИ играет важную роль в оказании клинической помощи и лечении заболеваний. Проблемы применения различных инструментов компьютерного зрения отражены во многих работах ученых и исследователей.

В работе авторов Д. А. Коблякова и др. [31] проведен анализ современных методов обработки медицинских изображений для устранения шумов и искажений, подчеркнута важность таких методов для точности диагностики и эффективности лечения. Авторы рассматривают линейные методы (фильтр среднего, медианный фильтр, Гаусса), нелинейные фильтры и методы на основе ИИ (сверточные нейронные сети). Представлен сравнительный анализ методов с рекомендациями по выбору и обозначены перспективные направления: разработка более эффективных алгоритмов, использование глубокого обучения и стандартизация методов обработки.

В работе авторов Горелова М.А. и др. [32] освещено использование капсульных нейронных сетей (КНС) для анализа медицинских изображений. Авторы отмечают сложность анализа медицинских изображений, связанную с необходимостью учета сложных геометрических отношений между объектами на изображении и их взаимосвязи. В работе подчеркнуты преимущества КНС перед традиционными СНС для анализа медицинских изображений, приведены примеры применения КНС в медицине - диагностика онкологических заболеваний, анализ кардиологических изображений, анализ изображений головного мозга. В работе представлены результаты исследования, проведенного авторами, которые демонстрируют эффективность КНС для анализа медицинских изображений. Авторы показывают, что КНС превосходят СНС по точности и скорости анализа медицинских изображений и указывают на ключевые направления дальнейшего развития применения КНС.

В работе Щукиной Н.А. [33] освещено применение нейронных сетей для классификации медицинских изображений. Автор отмечает важность автоматической классификации медицинских изображений для повышения точности диагностики и эффективности лечения. Нейронные сети предлагают

перспективный инструмент для решения этой задачи. Автор приводит обзор различных типов нейронных сетей: сверточные (извлечение признаков), рекуррентные (анализ динамики) и генеративно-состязательные (генерация данных), а также методы их обучения и примеры применения в разных медицинских областях.

Работа авторов Ковалева В.А. и др. [34] посвящена сравнению трёх методов глубокого обучения для сегментации поражений лёгких, связанных с COVID-19, на 3D КТ-изображениях. Авторы подчеркивают важность точной сегментации поражений лёгких для оценки тяжести COVID-19, мониторинга динамики заболевания и выбора оптимального метода лечения. В работе проведено сравнение трех методов глубокого обучения для сегментации поражений лёгких:

- U-Net - классический метод глубокого обучения для сегментации изображений;
- 3D U-Net - расширение U-Net для обработки 3D изображений, что делает его более подходящим для анализа КТ-сканов;
- V-Net - метод глубокого обучения для сегментации 3D изображений, основанный на модульной архитектуре.

Авторы провели эксперименты на наборе данных КТ-сканов лёгких пациентов с COVID-19. Они обучали и тестировали все три метода глубокого обучения и сравнивали их по точности и скорости сегментации. Результаты исследования показывают, что все указанные методы глубокого обучения способны эффективно сегментировать поражения лёгких на КТ-сканах. Однако 3D U-Net и V-Net показывают более высокую точность сегментации по сравнению с U-Net. Авторы анализируют преимущества и недостатки каждого метода глубокого обучения и делают вывод о том, что 3D U-Net и V-Net являются более перспективными для анализа изображений поражений лёгких на КТ-сканах с помощью метода сегментации.

В работе авторов Абульханова С.Р. и др. [35] предложены методика устранения шумов и коррекции искажений, методы анализа текстурных изменений в тканях и органах, глубокие нейронные сети для автоматизированного

обнаружения признаков патологии. Указанная технология демонстрирует перспективность в повышении скорости и точности диагностики, а также в возможности ранней детекции заболеваний, что может положительно сказаться на прогнозе для пациентов. Подчёркивается, что разработанный подход может быть адаптирован для различных видов медицинской визуализации, включая рентгенографию, ультразвуковое исследование и компьютерную томографию. В качестве приоритетных направлений для будущих исследований названы разработка более прецизионных алгоритмов обработки изображений, расширение и улучшение качества обучающих данных для нейронных сетей и интеграция разрабатываемой системы с существующими медицинскими платформами для обеспечения комплексного подхода к диагностике.

Исследование опыта применения инструментов компьютерного зрения в МИС позволяет сделать следующие выводы.

Современные исследования в области обработки и анализа медицинских изображений демонстрируют прогрессирующую интеграцию методов искусственного интеллекта и глубокого обучения, направленную на преодоление ограничений традиционных диагностических подходов. Важным аспектом становится оптимизация этапа предобработки данных, где комбинирование линейных фильтров (медианных, Гауссовых) с нелинейными алгоритмами позволяет минимизировать шумы и артефакты без потери значимых деталей. При этом нейросетевые методы, такие как сверточные сети, демонстрируют превосходство в адаптивном подавлении сложных искажений, характерных для рентгеновских снимков или КТ-сканов, что подтверждается сравнительными исследованиями эффективности на гетерогенных медицинских датасетах. Эволюция нейросетевых архитектур ориентирована на преодоление ключевых проблем медицинской визуализации — от низкой контрастности патологических участков до пространственной сложности анатомических структур. Капсульные сети, в отличие от классических CNN, обеспечивают сохранение иерархических отношений между объектами за счет динамической маршрутизации, что критично для дифференциации опухолевых образований с вариативной морфологией.

Параллельно развиваются гибридные подходы, сочетающие генеративно-состязательные сети (GAN) для синтеза аннотированных данных с рекуррентными архитектурами, анализирующими временные изменения в динамических исследованиях, таких как эхокардиография или перфузионная КТ.

Сегментация патологических зон, являющаяся основой для количественной оценки тяжести заболеваний, претерпевает трансформацию благодаря внедрению трёхмерных архитектур. Сравнительный анализ модификаций U-Net для обработки объемных данных выявил преимущества 3D U-Net и V-Net в контексте точности выделения COVID-19-индуцированных инфильтратов, где учет пространственных корреляций между срезами повышает воспроизводимость результатов. Эти методы не только улучшают точность пограничной детекции, но и позволяют автоматизировать расчет объема поражения, что существенно для объективизации прогноза. Инновационным направлением становится разработка высокочувствительных алгоритмов, направленных на выявление доклинических стадий патологий. Комбинация многоуровневой фильтрации, методов усиления текстурных особенностей и нейросетевой классификации позволяет идентифицировать. Ключевым вызовом остается обеспечение баланса между чувствительностью и специфичностью, поскольку избыточная детализация может приводить к ложноположительным результатам.

Перспективы применения инструментов компьютерного зрения связаны с созданием мультимодальных платформ, объединяющих алгоритмы предобработки, сегментации и классификации в единый диагностический контур. Приоритетными задачами являются стандартизация методов оценки качества обработки изображений, разработка открытых датасетов с экспертными разметками и внедрение механизмов интерпретируемости моделей для клинического аудита. Устранение дисбаланса между вычислительной сложностью 3D-анализа и требованиями к времени обработки в режиме реального времени остается критическим фактором для интеграции таких систем в рутинную практику.

1.1.3 Анализ опыта применения нечеткой логики в МИС и СППВР

Применение нечеткой логики в медицинских системах и системах поддержки принятия врачебных решений обусловлено ее способностью формализовать неопределенность и субъективность клинических данных. Врачебные заключения часто опираются на качественные признаки (например, «умеренная боль», «слабо выраженный отек»), которые не могут быть точно описаны бинарными или числовыми значениями. Нечеткие множества и лингвистические переменные позволяют моделировать градуированные оценки симптомов, сопоставляя их с вероятностными диагнозами. Это особенно важно при интерпретации субъективных жалоб пациентов, неоднозначных результатов исследований или пограничных значений лабораторных показателей. Кроме того, нечеткие системы обеспечивают прозрачность принятия решений за счет использования правил, близких к естественному врачебному мышлению («ЕСЛИ температура высокая И лейкоциты повышены, ТО вероятность инфекции умеренно высокая»), что упрощает интеграцию экспертных знаний и адаптацию моделей под конкретные клинические протоколы.

В работе Гермашева И.В. и других авторов [36] рассматривается применение нечеткой логики для обработки неопределенных и неточных медицинских данных, обусловленных субъективностью измерений и размытостью клинических понятий. Авторы обосновывают преимущество нечетких моделей перед классическими методами в медицинской диагностике, анализируя нечеткие экспертные системы, нейронные сети и гибридные подходы. Приведены примеры использования нечеткой логики в диагностике сердечно-сосудистых, онкологических и неврологических заболеваний. Отмечено, что нечеткие модели повышают гибкость, интерпретируемость и адаптивность диагностических систем, однако их применение ограничено сложностями в определении функций принадлежности, параметризации и валидации. Авторы подчеркивают необходимость дальнейших исследований для расширения использования нечеткой логики в клинической практике.

В исследовании Пановой И.В. и Токмаковой С.Е. [37] рассматривается применение методов нечеткой логики для диагностики почечных патологий, что актуально в связи с необходимостью обработки неопределенных и субъективных данных, характерных для клинической практики. Авторы подчеркивают, что традиционные подходы к диагностике часто не учитывают размытость симптомов и вариабельность лабораторных показателей, что может приводить к ошибкам в постановке диагноза. В качестве решения предложена модель принятия решений, основанная на нечетких множествах, которая позволяет формализовать качественные признаки, такие как степень выраженности симптомов или отклонения в анализах мочи и крови. Модель включает этапы фазификации входных данных, формирования базы нечетких правил на основе экспертных знаний и процедуру логического вывода, обеспечивающую интерпретацию данных в контексте возможных диагнозов. В статье приведен пример применения модели для дифференциальной диагностики хронической болезни почек, пиелонефрита и гломерулонефрита, где продемонстрирована возможность учета множества факторов, включая анамнез, клинические симптомы и результаты инструментальных исследований. Авторы отмечают, что использование нечеткой логики позволяет повысить точность диагностики за счет учета неопределенности данных и обеспечения прозрачности процесса принятия решений. В заключение подчеркивается потенциал модели для интеграции в медицинские информационные системы с целью поддержки врачебных решений, а также необходимость дальнейших исследований для оптимизации параметров модели и расширения ее функциональных возможностей.

В работе Маннаа А.С. [38] предложен алгоритм обработки рентгеновских изображений с использованием методов нечеткой логики, что актуально в контексте повышения качества анализа медицинской визуализации. Автор отмечает, что традиционные методы обработки изображений часто сталкиваются с проблемами, связанными с низким качеством снимков, наличием шумов и неоднородностью структур, что затрудняет интерпретацию данных. Для решения этих задач разработан алгоритм, основанный на нечеткой логике, который позволяет

эффективно сегментировать и классифицировать области интереса на рентгеновских снимках. Алгоритм включает этапы предварительной обработки изображений, фаззификации данных для учета неопределенности в интенсивности пикселей, а также применение нечетких правил для выделения патологических участков. Особое внимание уделено адаптивности алгоритма, что позволяет учитывать вариабельность характеристик изображений в зависимости от типа исследования и индивидуальных особенностей пациентов. В статье приведены результаты экспериментальной оценки алгоритма на наборе рентгеновских снимков, где продемонстрирована его эффективность в сравнении с традиционными методами обработки. Автор подчеркивает, что использование нечеткой логики обеспечивает более точное выделение границ патологических областей и снижает влияние шумов, что способствует повышению диагностической ценности изображений. В заключение отмечены перспективы применения алгоритма в системах поддержки принятия врачебных решений, а также необходимость дальнейших исследований для оптимизации его параметров и расширения функциональных возможностей.

В исследовании Гермашева И.В. и Дубовской В.И. [39] рассматривается применение моделей нечеткой математики для решения задач медицинской диагностики, что особенно актуально в условиях неопределенности и субъективности клинических данных. Авторы подчеркивают, что традиционные математические методы часто оказываются недостаточно эффективными для обработки размытых и неполных данных, характерных для медицинской практики. В качестве альтернативы предложены подходы, основанные на нечеткой логике, позволяющие формализовать качественные признаки, такие как степень выраженности симптомов или отклонения в лабораторных показателях. В статье подробно описаны основные принципы построения нечетких моделей, включая этапы фаззификации входных данных, формирования базы нечетких правил и процедуры логического вывода. Авторы анализируют различные типы нечетких моделей, такие как нечеткие экспертные системы, нечеткие нейронные сети и гибридные подходы, которые интегрируют нечеткую логику с другими методами

искусственного интеллекта. Приведены примеры применения нечетких моделей в диагностике сердечно-сосудистых, онкологических и неврологических заболеваний, где продемонстрирована их способность учитывать неопределенность данных и повышать точность диагностики. Особое внимание уделено интерпретируемости нечетких моделей, что делает их более понятными для медицинских специалистов и способствует их внедрению в клиническую практику. В заключение авторы отмечают, что использование нечеткой математики позволяет не только улучшить качество диагностики, но и автоматизировать процесс принятия решений, что особенно важно в условиях дефицита времени и ресурсов. Однако подчеркивается необходимость дальнейших исследований для решения проблем, связанных с определением функций принадлежности, параметризацией моделей и их валидацией в реальных клинических условиях.

В работе Коробова Л.А. и Гладких Т.В. [40] представлена разработка модели принятия решений для диагностики заболеваний, основанной на принципах нечеткой логики. Авторы акцентируют внимание на проблеме обработки неопределенных и неточных данных, характерных для медицинской диагностики, где традиционные методы часто оказываются недостаточно эффективными. В качестве методологической основы предложен подход, использующий нечеткие множества и лингвистические переменные, что позволяет формализовать субъективные и размытые клинические признаки, такие как интенсивность симптомов или степень выраженности патологических изменений. Модель включает этапы формирования базы правил, основанных на экспертных знаниях, и процедуру нечеткого вывода, которая обеспечивает интерпретацию входных данных в контексте диагностических гипотез. Авторы подробно описывают архитектуру системы, включая модули фаззификации, логического вывода и дефаззификации, что позволяет преобразовать качественные характеристики в количественные оценки вероятности диагноза. В качестве примера применения модели рассмотрена диагностика заболеваний, связанных с нарушениями работы желудочно-кишечного тракта, где продемонстрирована возможность учета множества факторов, включая анамнез, лабораторные показатели и субъективные

жалобы пациента. Особое внимание уделено вопросам интерпретируемости модели, что является ключевым аспектом для ее внедрения в клиническую практику. Авторы подчеркивают, что использование нечеткой логики позволяет не только повысить точность диагностики, но и обеспечить прозрачность процесса принятия решений, что способствует доверию со стороны медицинских специалистов. В заключение статьи отмечены перспективы дальнейшего развития модели, включая интеграцию с методами машинного обучения для повышения адаптивности и расширения функциональных возможностей системы.

В работе Махарова К. [41] исследуются методы формирования базы нечётких правил для интеллектуальных систем поддержки принятия решений, актуальных в условиях неопределённости данных. Автор подчёркивает ограниченность традиционных логических подходов при работе с размытыми входными параметрами и субъективными критериями, характерными для реальных задач в медицине, экономике и управлении. Рассмотрены два ключевых подхода к созданию нечётких правил: экспертно-ориентированный (ручное конструирование на основе знаний специалистов) и дата-драйвенный (автоматическая генерация через машинное обучение и оптимизационные алгоритмы). Особый акцент сделан на гибридных методах, сочетающих извлечение паттернов из данных с последующей экспертной корректировкой, что повышает адаптивность систем. Отмечены преимущества нечётких систем, включая интерпретируемость правил и устойчивость к противоречивой информации, а также сложности параметризации функций принадлежности, риски переобучения и необходимость кросс-валидации в предметных областях. Автор заключает, что совершенствование алгоритмов синтеза правил с учётом контекстной специфики задач — ключевое направление для повышения эффективности интеллектуальных систем.

Обобщая опыт применения нечеткой логики в МИС и СППВР, можно выделить несколько ключевых аспектов.

Во-первых, использование нечеткой математики для обработки неопределенных, размытых и субъективных данных, характерных для клинической практики, актуально. Традиционные методы анализа зачастую оказываются

недостаточно эффективными для работы с такими данными, что приводит к необходимости разработки более гибких и адаптивных подходов.

Во-вторых, необходима разработка конкретных моделей и алгоритмов, основанных на нечеткой логике, которые бы позволили формализовать качественные признаки, такие как степень выраженности симптомов, отклонения в лабораторных показателях или особенности медицинских изображений. Эти модели включают этапы фаззификации входных данных, формирования базы нечетких правил на основе экспертных знаний и процедуры логического вывода, что обеспечивает интерпретацию данных в контексте диагностических гипотез.

Третьим важным аспектом является интерпретируемость и прозрачность применения нечетких моделей, что делает их более понятными для медицинских специалистов и способствует их внедрению в клиническую практику, нечеткие системы позволяют учитывать экспертные знания и обрабатывать неполные данные, что повышает адаптивность и применимость моделей в реальных условиях.

Кроме того, применение нечеткой логики в различных областях медицины, включая диагностику сердечно-сосудистых, онкологических, неврологических и почечных заболеваний, а также обработку медицинских изображений, распространены достаточно широко. Это демонстрирует универсальность и эффективность нечетких моделей для решения широкого спектра диагностических задач.

Однако, при использовании нечеткой логики в медицине, существует необходимость оптимизации параметров нечетких моделей, решения проблем, связанных с определением функций принадлежности и валидацией моделей, а также для интеграции нечеткой логики с другими методами искусственного интеллекта, такими как нейронные сети и машинное обучение. Это открывает перспективы для создания более сложных и адаптивных систем поддержки принятия врачебных решений, способных улучшить качество и эффективность медицинской диагностики.

1.2 Обзор современных инструментов компьютерного зрения для анализа медицинских изображений

Технологии компьютерного зрения и искусственного интеллекта находят применение в разных сферах человеческой деятельности. Важным и интересным направлением, где возможно применение данных технологий, является анализ объектов на медицинских изображениях. На сегодняшний день анализ МИ и поиск объектов на них широко применяется в медицинской диагностике – от анализа крови до магнитно-резонансной томографии. Анализ МИ играет важную роль в оказании клинической помощи и лечении заболеваний. Например, анализ рентгеновских снимков является лучшим подходом для диагностики пневмонии.

В настоящее время существуют следующие методы анализа медицинских изображений: классификация объектов на изображениях, детектирование объектов на изображениях, сегментация объектов на изображениях. Каждый из методов предназначен для решения разного рода задач в медицине при постановке диагноза.

1.2.1 Анализ медицинских изображений с помощью сегментации

Одним из ключевых этапов анализа медицинских изображений является сегментация, позволяющая проводить количественный анализ характеристик органов, таких как размер, форма и объем. Суть задачи сегментации заключается в определении групп пикселей, формирующих контуры или представляющих отдельные объекты [42]- [44].

Применение сегментации в медицинской визуализации открывает широкие возможности для повышения эффективности диагностики и лечения. Сегментация медицинских изображений может быть использована для:

- постановки диагноза, сегментация позволяет точно определить размер и форму опухолей, выявить аномалии в структуре органов, определить степень поражения тканей при заболеваниях;
- планирования лечения, сегментация помогает определить точную область для хирургического вмешательства, разработать индивидуальные планы радиотерапии, оптимизировать и персонализировать лечение;

- мониторинга лечения, сегментация позволяет отслеживать изменения в органах в динамике, оценивать эффективность лечения, предотвращать возможные осложнения.

Существует множество методов автоматизированной сегментации, каждый из которых имеет свои преимущества и недостатки. В работе было проведено исследование существующих методов сегментации медицинских изображений. Методы сегментации бывают трёх видов: структурные, стохастические и смешанные [45]- [47].

Структурные методы используют информацию о структуре объекта, которая подлежит сегментации. К ним относятся: декомпозиция графов, граничные методы, морфологические методы, модели активного контура, динамические деформируемые модели, вероятностные деформируемые модели, а также активные контуры и потоки векторных градиентов. Эти методы позволяют сегментировать отдельные объекты или области, представляющие интерес. Однако они не полностью автоматизируются, а точность сегментации зависит от высокого разрешения исходных изображений.

Стохастические методы анализа медицинских изображений основаны на статистическом анализе данных. К ним относятся пороговая классификация, статистические классификаторы, кластерный анализ и модели на основе случайных полей Маркова. В отличие от структурных методов, стохастические подходы характеризуются большей степенью автоматизации. Однако, они могут испытывать затруднения при анализе отдельных областей изображения, требующих учета контекстной информации.

Комбинированные (смешанные) методы анализа медицинских изображений интегрируют характеристики как структурных, так и стохастических подходов. К ним относятся: метод наращивания областей, методы, основанные на атласах, метод «разделить и объединить», модель LEGION и искусственные нейронные сети.

Для решения задачи поиска объектов почек и камней в почках методы сегментации медицинских изображений, полученных по результатам

компьютерной томографии внутренних органов человека, не подошли. Как показало проведенное исследование, объекты камней обнаруживаются с помощью методов сегментации по порогу и региональным наращиванием. Однако и в данных методах имеются свои ограничения. Сегментация по порогу определяет все объекты выше указанного порога, в том числе кости таза, ребер, позвоночника. Сегментация региональным наращиванием для поиска камней связана с удачным определением начальных координат сегментации, что в задаче поиска объектов почек и камней на изображении является заранее неизвестным.

Сегментация с помощью нейронных сетей и машинного обучения сталкивается с трудностями создания аннотированного датасета для обучения нейросети. В настоящее время датасеты для сегментации с помощью нейросетей объектов почек и камней в свободном доступе отсутствуют, а создание хорошего датасета требует значительных человеческих ресурсов, высококвалифицированных в данной области медицины, поэтому пока данный подход остается перспективой для дальнейших исследований.

1.2.2 Анализ медицинских изображений с помощью классификации

Классификация объектов на медицинских изображениях позволяет определить на изображении наличие или отсутствие какой-либо медицинской патологии [48]-[49].

Классификация медицинских изображений с помощью нейросетей — это мощный инструмент для автоматизации диагностики и анализа медицинских данных. Она позволяет врачам быстро и точно определять заболевания, оценивать состояние пациента и принимать обоснованные решения [50]-[55]. Процесс классификации с помощью нейросети можно разбить на следующие этапы.

Этап подготовки данных:

- сбор набора медицинских изображений, размеченных по категориям заболеваний;
- преобразование изображений в формат, удобный для обработки нейросетью (например, нормализация, изменение размера);

- разделение данных на обучающий, валидационный и тестовый наборы.

Этап обучения модели:

- выбор подходящей архитектуры нейросети,
- обучение модели на обучающем наборе данных,
- оптимизация параметров модели с помощью методов машинного обучения для достижения максимальной точности.

Этап классификации новых изображений:

- ввод нового медицинского изображения в обученную нейросеть,
- получение предсказания от модели — вероятности принадлежности изображения к каждой из категорий заболеваний,
- выбор категории с наибольшей вероятностью как результат классификации.

Сверточные нейронные сети (CNN) являются наиболее популярным типом нейросетей для анализа изображений. Они эффективно извлекают пространственные признаки из изображений и используют слои свертки и пулинга для сокращения размерности данных.

Классификация медицинских изображений с помощью нейросетей — это динамично развивающееся направление, обещающее значительный прогресс в диагностике и лечении заболеваний. При тщательной разработке и оценке нейросети могут стать ценным инструментом для улучшения качества медицинской помощи. Однако с помощью данного инструмента нельзя локализовать на снимке место обнаруженной патологии.

1.2.3 Поиск объектов на медицинских изображениях с применением детектирования

Детектирование объектов в медицинских изображениях с помощью нейросетей — это ключевой инструмент для автоматизации диагностики и анализа. Оно позволяет автоматически идентифицировать и локализовать важные объекты, такие как опухоли, аномалии органов, кости, или другие структуры, на рентгеновских снимках, МРТ, КТ и других медицинских изображениях. Детектирование объектов на МИ с использованием ИНС позволяет не только

отличить изображения с патологией или без таковой, но и локализовать место патологии на снимке. Кроме того, детектирование позволяет находить на изображениях несколько объектов различных заданных классов, вычислить размеры найденных объектов, что поможет медикам-диагностам в постановке правильного диагноза [56]-[61]. Процесс детекции объектов с помощью нейросети можно разбить на следующие этапы.

Этап подготовки данных, на котором выполняются следующие действия:

- сбор набора медицинских изображений, размеченных по классам объектов (например, опухоли, органы, кости);
- аннотация данных - ручное выделение областей, соответствующих каждому объекту на изображениях;
- преобразование изображений в формат, удобный для обработки нейросетью;
- разделение данных на обучающий, валидационный и тестовый наборы.

Этап обучения модели, где осуществляется:

- выбор подходящей архитектуры нейросети для детектирования объектов,
- обучение модели на обучающем наборе данных,
- оптимизация параметров модели с помощью методов машинного обучения для достижения максимальной точности.

Далее следует этап детектирования объектов на новых изображениях, где выполняется:

- ввод нового медицинского изображения в обученную нейросеть,
- получение предсказания от модели в виде координат и наименований классов найденных на изображении объектов,
- визуализация - нанесение ограничивающих рамок вокруг обнаруженных объектов на исходном изображении.

В результате детектирования объектов на МИ с помощью ИНС вычисляются следующие параметры: класс найденного объекта, координаты центра, размеры по вертикали и горизонтали ограничивающего найденный объект прямоугольника.

Полученные параметры в дальнейшем можно использовать для расчетов различных характеристик, необходимых медикам для правильной постановки диагноза: размеры объекта, количество объектов, отношение патологических объектов к общему количеству найденных объектов и других параметров [62], [63].

Нейросети, с помощью которых может быть выполнена детектирование объектов в медицинских изображениях:

- YOLO (You Only Look Once) - высокоскоростная нейросеть, которая анализирует изображение за один проход для выявления всех объектов;

- Faster R-CNN (Regions with Convolutional Neural Networks) - двухэтапная нейросеть, сначала выделяет потенциальные области, содержащие объекты, а затем классифицирует их;

- SSD (Single Shot MultiBox Detector) - одноступенчатая нейросеть, которая прямо предсказывает классы и координаты объектов, используя сверточные слои.

Преимущества детектирования объектов с помощью нейросетей следующие.

Автоматизация процесса детектирования объектов экономит время специалистов и позволяет обработать большие объемы данных.

Улучшается точность диагностики заболевания - нейросети могут обнаружить незаметные для глаза человека патологии.

Детектирование объектов позволяет быстрее и эффективнее выполнять различные медицинские задачи, такие как планирование операций.

Однако детектирование имеет ряд ограничений в применении для поиска объектов на МИ. Для обучения нейросети необходимо собрать большой набор медицинских изображений, размеченных по классам объектов. Нейросети могут давать неверные результаты, особенно в сложных случаях.

Детектирование объектов с помощью нейросетей — это перспективное направление в медицинской визуализации, которое обещает значительный прогресс в диагностике и лечении заболеваний. При тщательной разработке и оценке нейросети могут стать ценным инструментом для улучшения качества медицинской помощи.

1.3 Применение искусственных нейронных сетей для поиска объектов на медицинских изображениях

1.3.1 Исследование архитектур искусственных нейронных сетей для анализа медицинских изображений

В настоящее время существует достаточно большое количество архитектур сверточных нейронных сетей, применяемых при разработке технологий компьютерного зрения: LeNet-5, AlexNet, VGG-16, ResNet-50, Xception, ResNets, R-CNN, Fast RCNN, YOLO. Почти все архитектуры CNN следуют одним и тем же общим принципам проектирования: последовательного применения сверточных слоев к входным данным, и периодического уменьшения пространственных размеров и увеличения количества карт признаков объектов [64]-[73].

YOLO — это сеть, предназначенная для идентификации и распознавания объектов на изображениях в реальном времени. YOLO работает по принципу «one-shot» обнаружения, где изображение анализируется только один раз для выявления всех объектов. YOLO накладывает на изображение сетку размера $s \times s$. Для каждой из полученных ячеек определяется вероятность принадлежности к каждому возможному классу. Отдельно обговаривается, что одна ячейка может принадлежать нескольким классам (ситуация, когда один объект частично загоразивает другой). Далее сеть визуализирует полученные результаты, очерчивая рамками найденные объекты. Главным преимуществом YOLO является сравнительно небольшие затраты времени на анализ изображения и простота использования [74]-[77].

YOLOv5 — это мощный алгоритм обнаружения объектов, разработанный компанией Ultralytics. YOLOv5 представляет собой современную state-of-the-art (SOTA) реализацию алгоритмов семейства YOLO (You Only Look Once), аккумулирующую достижения предыдущих версий и отличающуюся расширенным функционалом, направленным на оптимизацию ключевых характеристик, таких как производительность, гибкость и вычислительная эффективность. Архитектура YOLOv5 обеспечивает поддержку широкого спектра задач в области искусственного интеллекта, включая объектное детектирование,

семантическую сегментацию, оценку позы, отслеживание траектории движения и классификацию изображений. Данная multifunctionality позволяет интегрировать возможности YOLOv5 в гетерогенные приложения и предметные области [78]-[80].

В архитектуре YOLOv5 используются следующие слои [79]:

- сверточные слои, которые извлекают пространственные признаки из изображения;
- пулинг слои, которые сводят размерность изображения, уменьшая количество вычислений;
- полносвязные слои, которые преобразуют извлеченные признаки в вероятности наличия объектов и их координаты.
- нелинейные функции активации, которые вносят нелинейность в модель для более точной обработки данных.

Архитектура состоит из трех основных частей (рисунок 1.3) [80]:

- скелет — это основная часть сети. Для YOLOv5 скелет был спроектирован с использованием обновленной CSP-Darknet53 структуры, которая является модификацией архитектуры Darknet, использованной в предыдущих версиях YOLO;
- шея - эта часть соединяет скелет и голову. В YOLOv5 используются структуры SPPF и New CSP-PAN;
- головная часть (head) - отвечает за генерацию финальных выходных данных. В архитектуре YOLOv5 для этих целей используется YOLOv3 Head.

Одной из ключевых особенностей архитектуры YOLOv5 является применение механизма самовнимания (self-attention) в головной части сети. Этот механизм позволяет модели динамически фокусироваться на различных областях входного изображения и устанавливать весовые коэффициенты для различных признаков, определяя их релевантность для решаемой задачи.

Другой важной характеристикой YOLOv5 является способность к многомасштабному объектному детектированию. Для обнаружения объектов различных размеров и масштабов в изображении модель использует

пирамидальную сеть признаков (Feature Pyramid Network, FPN). FPN состоит из нескольких слоев, обеспечивающих обнаружение объектов на различных пространственных разрешениях, что позволяет модели эффективно детектировать как крупные, так и малоразмерные объекты.

Для улучшения способности модели к обобщению и уменьшения переобучения в YOLOv5 используются различные методы дополнения данных. Эти методы включают:

- мозаичное наращивание - техника, предполагающая объединение четырёх тренировочных изображений в одно составное, что позволяет модели лучше распознавать объекты, представленные в различных масштабах и положениях;

- copy-paste augmentation - инновационный подход, заключающийся в случайном копировании фрагментов одного изображения и последующем их наложении на другое;

- случайные аффинные преобразования - метод, основанный на случайных поворотах, масштабировании и сдвигах изображений, что позволяет увеличить разнообразие тренировочных данных;

- mixup augmentation - техника, позволяющая формировать новые изображения путем линейной комбинации пиксельных значений двух исходных изображений и соответствующих им меток классов;

- albumentations - мощная библиотека для дополнения изображений, поддерживающая широкий спектр методов дополнения;

- увеличение HSV - произвольное изменение оттенка, насыщенности и ценности изображений.

- случайное горизонтальное переворачивание - метод, при котором производится случайный переворот изображения по горизонтали.

Для повышения эффективности обучения модели применяются следующие усовершенствованные стратегии оптимизации:

- многомасштабное обучение - на этапе тренировки нейронной сети входные изображения случайным образом масштабируются, при этом коэффициент масштабирования варьируется от 0,5 до 1,5 относительно оригинального размера.

Данный подход обеспечивает устойчивость модели к изменениям масштаба объектов интереса;




Рисунок 1.3 – Архитектура YOLOv5

– автоматическая настройка якорных прямоугольников (AutoAnchor) - реализована методика адаптивной настройки параметров априорных рамок-кандидатов (anchor boxes) для максимального соответствия статистическим характеристикам объектов, представленных в целевом наборе данных. Это позволяет оптимизировать процесс обнаружения объектов различной формы и размеров;

- адаптивное управление скоростью обучения (Warmup and Cosine LR Scheduler). Применяется метод динамической регулировки параметра скорости обучения, включающий начальный этап “разогрева” (warmup), за которым следует снижение скорости по косинусоидальному закону. Такой подход способствует более эффективной сходимости алгоритма и снижает вероятность переобучения;

- экспоненциальное сглаживание параметров (Exponential Moving Average, ЕМА). Для стабилизации процесса обучения и повышения обобщающей способности модели используется усреднение весов нейронной сети с применением экспоненциально убывающего окна;

- вычисления со смешанной разрядностью (Mixed Precision Training). С целью снижения вычислительной нагрузки и уменьшения объема занимаемой памяти используется гибридный подход, при котором часть операций выполняется с использованием чисел половинной точности (FP16);

- эволюционная оптимизация гиперпараметров (Hyperparameter Evolution). Реализована автоматизированная процедура подбора оптимальных значений гиперпараметров модели с использованием эволюционных алгоритмов, что позволяет повысить общую производительность системы.

YOLOv5 представляет собой существенный прогресс в развитии моделей объектного детектирования, функционирующих в режиме реального времени. Интегрируя широкий спектр инновационных функций, улучшений и передовых стратегий обучения, YOLOv5 превосходит предшествующие версии семейства YOLO по ключевым показателям производительности и эффективности. К основным усовершенствованиям следует отнести внедрение динамической архитектуры, расширенный набор методов аугментации данных, применение инновационных подходов к обучению, а также значительные модификации в функции потерь и процессе формирования целевых меток. Совокупность указанных нововведений обеспечивает существенное повышение точности и эффективности объектного детектирования при сохранении высокой скорости обработки информации.

Нейросеть архитектуры YOLO успешно применяется в различных медицинских задачах, включая обнаружение опухолей на рентгеновских снимках, МРТ и КТ, автоматическую сегментацию органов на медицинских изображениях, анализ медицинских изображений для диагностики различных заболеваний, извлечение информации из медицинских изображений для анализа и принятия решений [81], [84].

Однако применение YOLO для анализа МИ имеет свои особенности. Для достижения высокой точности YOLO требуется значительная база данных размеченных медицинских изображений. Ограниченная интерпретация результатов определения объектов - YOLO предоставляет информацию о расположении и вероятности объекта, но не дает глубокого понимания характеристик найденного объекта. YOLO – это мощная нейросеть, которая уже нашла широкое применение в медицинской диагностике и анализе изображений. Она обладает рядом преимуществ, таких как высокая скорость, точность и простота реализации. Однако, для достижения оптимальных результатов необходимо учитывать особенности работы YOLO в медицинской области [85]-[88].

1.3.2 Критерии оценки качества определения объектов на МИ с применением нейросетей

Оценка качества работы нейросетевых алгоритмов при определении объектов на МИ требует комплексного подхода, учитывающего как технические метрики эффективности моделей, так и клиническую релевантность результатов. Основным критерием точности детекции выступает «полнота» (recall) и «точность» (precision), количественно отражающие соотношение корректно идентифицированных объектов к общему числу релевантных патологий и ложноположительным срабатываниям соответственно. Для интегральной оценки баланса между этими параметрами применяется «F1-мера» (F1-score), гармонически усредняющая полноту и точность, что особенно критично в условиях дисбаланса классов, характерного для редких патологий [89].

В задачах сегментации ключевыми метриками становятся «коэффициент Dice» (Dice Similarity Coefficient, DSC) и «Intersection over Union» (IoU), оценивающие степень совпадения предсказанных масок с экспертной разметкой. DSC, рассчитываемый как удвоенная площадь пересечения предсказанной и эталонной областей, нормированная на их суммарную площадь, демонстрирует устойчивость к вариациям размеров объектов, что актуально при анализе мелких или диффузных патологий. IoU, в свою очередь, обеспечивает строгую оценку качества локализации границ, критичную для планирования хирургических вмешательств.

Для оценки общей производительности моделей в условиях многоклассовой классификации используется «матрица ошибок (confusion matrix)» с последующим расчетом «чувствительности (sensitivity)» и «специфичности (specificity)», отражающих способность алгоритма минимизировать пропуск целевых патологий и ложные тревоги. Дополнительным инструментом выступает ROC-анализ (Receiver Operating Characteristic) с расчетом площади под кривой (AUC-ROC), позволяющий оценить устойчивость модели к изменению пороговых значений классификации, что важно для адаптации алгоритмов под требования различных клинических сценариев [90].

Важным аспектом является «клиническая валидация», включающая сравнение результатов нейросетевого анализа с заключениями экспертов-радиологов. Для этого применяются метрики «межэкспертной согласованности», такие как каппа-коэффициент Коэна (Cohen's kappa), устраняющий влияние случайных совпадений. Визуальная оценка качества, включающая анализ артефактов сегментации (например, фрагментация опухолей) и соответствия анатомическим ориентирам, дополняет количественные метрики, обеспечивая интегральную оценку применимости модели в реальной практике.

Учет «вычислительной эффективности» (время инференса, потребление ресурсов) становится критичным при внедрении систем в условия ограниченных аппаратных мощностей, например, в мобильные диагностические комплексы. Для оценки устойчивости алгоритмов к вариативности входных данных применяются

методы «аугментации» и тестирование на гетерогенных датасетах, включающих изображения, полученные на оборудовании разных производителей и с различными протоколами съемки.

Несмотря на широкое применение стандартизированных метрик для оценки качества нейросетевого анализа медицинских изображений, их использование при определении объектов на КТ-снимках внутренних органов сопряжено с рядом принципиальных ограничений, особенно в контексте ошибок взаимного расположения структур и ошибочной идентификации анатомических образований. Классические метрики, такие как DSC и IoU, фокусируются на количественном совпадении предсказанных и эталонных областей, игнорируя семантическую корректность локализации объектов. Например, алгоритм может достичь высоких значений DSC при сегментации печени, ошибочно сместив её границы в область селезенки, что нарушает анатомическую целостность модели и ведет к некорректной интерпретации пространственных отношений между органами. Такие ошибки остаются неучтенными, так как метрики не включают оценку топологической согласованности — соответствия предсказанного расположения органов их типичной анатомической конфигурации. Ошибочное определение органов, например, путаница между петлями кишечника и маткой или между долями печени и опухолевыми образованиями, также не отражается в стандартных показателях. Метрики точности и полноты оперируют бинарной логикой «правильно-неправильно» на уровне пикселей, не учитывая семантический контекст ошибок. Система, сегментирующая селезенку вместо левой почки, получит высокие количественные оценки, если форма и размер областей совпадают, несмотря на критическую диагностическую ошибку. Это связано с отсутствием в метриках компонента, оценивающего корректность классификации объектов, их соответствие априорным анатомическим знаниям. Кроме того, ROC-анализ и AUC-ROC, ориентированные на оценку баланса между чувствительностью и специфичностью, не учитывают пространственную природу ошибок. Ложноположительные срабатывания, расположенные в анатомически невозможных зонах (например, «опухоль» в проекции крупного сосуда), и

ложноотрицательные результаты, связанные с игнорированием атипично расположенных органов (ротация почки, эктопия), не дифференцируются в рамках данных метрик. Это ограничивает их применимость для задач, требующих учета физиологических и морфологических вариаций. Проблема усугубляется при анализе комплексных патологий, сопровождающихся деформацией органов (цирроз, крупные новообразования). Метрики, основанные на сравнении с эталонной маской, не способны оценить клиническую значимость отклонений — смещение сосудистых структур вследствие объемного процесса или компрессию соседних органов. Визуальная экспертиза, хотя и позволяет выявить такие ошибки, не формализована в виде количественных показателей, что затрудняет сравнение моделей в рамках масштабных исследований.

Для преодоления указанных ограничений перспективным направлением является разработка комбинированных метрик, интегрирующих топологический анализ (оценку взаимного расположения объектов) и семантическую валидацию (проверку принадлежности сегментированной области к ожидаемому анатомическому классу). Внедрение метрик, учитывающих клиническую критичность ошибок для конкретных органов, и использование онтологий анатомических отношений позволит повысить релевантность оценок, что особенно актуально для пограничных зон между органами со схожей радиологической плотностью.

Выводы первой главы

В данной главе проведено исследование современного состояния применения МИС и СППВР в различных областях медицины, помогающие врачам принимать более обоснованные решения в клинической практике и предоставляющие персонализированные рекомендации, прогнозы и варианты лечения на основании данных пациента, клинических протоколов, медицинских знаний и других источников информации.

Проведен анализ работ, посвященных исследованию опыта применения искусственного интеллекта в медицинских диагностических системах,

преимуществ и сложностей в использовании ИИ в МИС и СППВР, опыта применения мягких вычислений в данной области.

Исследован практический опыт разработки и применения МИС и СППВР в современной медицинской практике. Российские и международные системы МИС и СППВР активно развиваются, предоставляя врачам доступ к передовым технологиям, однако существуют сложности и ограничения в использовании данных систем.

Также проведен анализ опыта применения технологий компьютерного зрения для анализа медицинских изображений. Приведены наиболее распространенные методы анализа медицинских изображений, к которым относятся классификация объектов на изображениях, детектирование объектов на изображениях, сегментация объектов на изображениях. Проведено исследование архитектур искусственных нейронных сетей, применяемых для анализа медицинских изображений. Для решения задач детектирования объектов на изображениях в настоящее время широко используются алгоритмы, основанные на нейронных сетях архитектуры YOLO.

Результатом анализа КТ-снимка с использованием нейросетей должна быть трехмерная визуализация (сегментация) найденной патологии. Однако, решение задачи сегментации КТ-изображений нейросетями сталкивается с трудностями создания аннотированного датасета для обучения нейросети. Создание такого датасета связано с требованием наличия высоко квалифицированных в данной области медицины специалистов и громадных временных затрат, в открытом доступе пока таких данных недостаточно. Поэтому актуальна задача трехмерной реконструкции найденной на КТ-изображении патологии по результатам решения задачи детекции.

В целом, в настоящий момент в отечественной медицинской практике системы поддержки принятия решений в урологии, основанные на передовых методах компьютерного зрения, пока не получили широкого распространения. Поэтому разработка и дальнейшее усовершенствование таких систем является актуальной задачей.

Предлагаемое диссертационное исследование состоит из следующих основных этапов.

1. Реализация алгоритма обучения нейронной сети YOLOv5 для детектирования объектов заданных классов на медицинских изображениях, включающего автоматизированную процедуру создания обучающего датасета. Анализ результатов обучения нейросети.

2. Разработка метрик оценки качества обнаружения и классификации нейросетями объектов на медицинских изображениях. Разработка алгоритма нечеткой оценки результатов определения объектов на медицинских изображениях.

3. Разработка процедуры трехмерной сборки объектов, алгоритма расчета параметров и визуализации найденных объектов по результатам детектирования на медицинских изображениях.

4. Разработка системы поддержки принятия врачебных решений в урологии для автоматизированного подбора режимов работы лазерной установки по дроблению камней в почках с использованием полученных результатов нейросетевого детектирования и 3D-визуализации.

Глава 2 Разработка метода оценки результатов анализа медицинских изображений внутренних органов человека с применением инструментов компьютерного зрения

2.1 Оценка эффективности обучения нейронной сети и качества распознавания объектов заданных классов на медицинских изображениях нейросетью YOLO

Для проведения исследования и разработки СППРВ в урологии была определена диагностика мочекаменной болезни (МКБ) по результатам компьютерной томографии путем распознавания, детектирования и оценки конкрементов в почках методами компьютерного зрения. МКБ занимает второе место по частоте среди всех больных с урологической патологией и имеет свои эндемичные зоны как в России, так и в других странах мира. МКБ связана как правило с нарушением обмена веществ, в Крыму заболеваемость выше, чем в целом по стране. Медицинские данные для исследования были предоставлены Клиническим медицинским многопрофильным центром (КММЦ) имени Святителя Луки г. Симферополь, который обладает современной базой радиологии и уникальными методиками лечения МКБ.

Совместно со специалистами КММЦ был проведен анализ видов объектов для детектирования и отбор классов для формирования датасета и обучения нейросети. Условия предполагали детектирование следующих классов объектов:


- левая почка правильной формы – класс «left_kidney» - 0 класс;
- конкременты (камни) правильной формы – класс «stone» - 1 класс;
- правая почка правильной формы – класс «right_kidney» -2 класс;
- патологически увеличенная левая почка – класс «left_kidney_pieloectasy» - 3 класс;
- патологически увеличенная правая почка – класс «right_kidney_pieloectasy» - 4 класс;
- большой камень сложной формы (коралловидной формы) - класс «staghorn_stones»- 5 класс.

В дальнейшем данная классификация объектов была применена для проведения разметки изображений, создания обучающего датасета, обучения модели нейронной сети, проведения детектирования объектов на медицинских изображениях, полученных по результатам КТ внутренних органов пациента.

На основании проведенных исследований был сделан вывод, что для применения в системе поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения при лечении МКБ человека в качестве нейросети для определения объектов на медицинских изображениях, полученных в результате проведения компьютерной томографии, наилучшим образом подходит СНС архитектуры YOLOv5. Нейросеть YOLOv5 позволяет выполнять классификацию объектов на изображении, выполнять детектирование объектов, сегментировать объекты на изображении. После детектирования объектов нейросетью данной архитектуры в результате получаются изображения, где объекты заданной медицинской патологии (почки, камни) ограничены прямоугольником, также нейросеть формирует текстовый файл к каждому анализируемому МИ с описанием обнаруженных на данном изображении объектов: класс объекта, координаты центра ограничивающего прямоугольника, высоту и ширину данного прямоугольника, уверенность обнаружения данного объекта. С помощью указанных параметров при проведении дальнейших вычислений можно определить линейные размеры объектов.

2.1.1 Разработка процедуры создания обучающего датасета

Датасет для обучения нейросети архитектуры YOLOv5 представляет из себя набор изображений и описание объектов, представленных на изображениях, в виде набора текстовых файлов, в которых построчно указаны параметры объектов: класс объекта, координаты центра ограничивающего прямоугольника, его высота и ширина, приведенных в относительные координаты в диапазоне $[0, 1]$. Пример размеченного изображения с описанием разметки из текстового файла представлен на рисунке 2.1.



```
2 0.401042 0.256726 0.108631 0.217489
0 0.607887 0.290359 0.108631 0.208520
1 0.593750 0.253363 0.032738 0.035874
1 0.609375 0.306054 0.016369 0.024664
```

Рисунок 2.1 - Пример размеченного изображения (слева) с описанием разметки из текстового файла (справа)

Особенностью формирования обучающего датасета для нейросети, построенной по технологии YOLOv5, является то, что него необходимы изображения в формате JPG или PNG. После проведения процедуры КТ результаты сохраняются в стандарте DICOM, который не предполагает наличия изображений в указанных форматах. Поэтому было сначала необходимо получить из файлов в DICOM формате набор изображений в нужной проекции необходимого разрешения. Для этого был разработан программный модуль получения из снимков КТ формата DICOM изображений внутренних органов человека в корональной проекции [91].

В исследуемой области получить необходимое количество изображений для создания датасета нужного размера является проблематичным. Несмотря на то, что процедура КТ может давать множество материала (снимков), обучение проходит с использованием изображений, уже размеченных специалистами в предметной области, а это очень трудоемкий и долгий процесс. В связи с этим, в рамках диссертационной работы была разработана поэтапная процедура обучения, позволяющая минимизировать рутинную разметку изображений, сократить время на создание обучающей выборки. В силу высокой трудоемкости разметки формирование набора изображений для обучения производилось в три этапа. Подготовка изображений для создания обучающего датасета для обучения

нейронной сети велась на базе Клинического медицинского многопрофильного центра имени Святителя Луки г. Симферополь.

На первом этапе для обучения нейронной сети YOLOv5 разметку изображений проводили аспиранты и ординаторы Медицинской академии имени С.И. Георгиевского под руководством врачей-специалистов отделения урологии. Были было размечено всего 793 изображений КТ внутренних органов в корональной проекции 21 пациента. Для увеличения размера датасета автором была проведена процедура аугментации, не искажающая анатомическую правильность расположения внутренних органов, путем добавления фильтра «sharpening» (усиление резкости изображения) в исходные изображения. Конечный размер первичного обучающего датасета составил 1586 изображений. Для обучения была взята архитектура YOLOv5s. Обучение проводилось длительностью 1200 эпох средствами Google Colab, длительность обучения составила 26 часов.

На втором этапе версия модели нейросети YOLOv5 была обучена на датасете, содержащем 2075 изображений, в том числе 1582 оригинальных изображений, полученных путем детектирования снимков из КТ 24 пациентов с применением первоначально обученной модели нейросети после их проверки специалистами КММЦ. Остальные изображения были получены путем выполнения процедур аугментации и клонирования, описанными для первоначального этапа обучения. Обучение проводилось длительностью 600 эпох. Обучение проводилось с применением инструмента Google Colab, длительность обучения составила 22 часа.

На третьим этапе версия модели обучалась на датасете, содержащем 4272 изображения, полученных в результате детектирования КТ- снимков 38 пациентов второй обученной версией модели YOLO, после проверки результатов детектирования специалистами КММЦ. Обучение проводилось на высокопроизводительном ПК на графическом процессоре с использованием видеокарты Nvidia RTX 3090, ввиду ограниченности по времени доступа к инструменту Google Colab. Для обучения детектирования объектов была определена модель YOLOv5m, которая по сравнению с YOLOv5s обладает большим числом слоев, большим числом параметров, большей обучаемостью,

большей скоростью детектирования. Сравнительная характеристика данных двух моделей, представленная разработчиками YOLO, приведена в таблице 2.1 [80].

Таблица 2.1 – Сравнение параметров YOLOv5s и YOLOv5m

Model	size (pixels)	mAP ^{val} 0.5:0.95	mAP ^{val} 0.5	Speed CPU b1 (ms)	Speed V100 b1 (ms)	Speed V100 b32 (ms)	params (M)	FLOPs @640 (B)
YOLOv5s	640	37.4	56.8	98	6.4	0.9	7.2	16.5
YOLOv5m	640	45.4	64.1	224	8.2	1.7	21.2	49.0

Время обучения модели нейросети длительностью 600 эпох составило 240 часов.

Для самопроверки обучения нейросетью был создан валидационный датасет, содержащий 70 снимков, не входящих и не встречающихся в обучающем датасете.

2.1.2 Анализ результатов обучения нейросети

После обучения был проведен анализ показателей, характеризующих качество обучения. Анализ показал следующее.

Несмотря на увеличение количества изображений в датасете, соотношение количества размеченных объектов различных классов не изменилось по сравнению с первой версией обучающего датасета. Это объясняется неравномерностью разметки датасета, количество размеченных объектов классов почек было значительно больше количества объектов классов камней. Очевидно, что наиболее многочисленны объекты, характеризующие почки (правую и левую) и объекты, характеризующие класс «камень» (рисунок 2.2), количество размеченных объектов было следующим:

- класса «left_kidney» - 3487(32%);
- класса «stone» - 2277 (21%);
- класса «right_kidney» - 3415 (31%);
- класса «left_kidney_pieloectasy» - 318 (3%);
- класса «right_kidney_pieloectasy» - 518 (5%);
- класса «staghorn_stones» - 733 (7%).

Суммарно оставшиеся объекты представляют лишь 15% от общего количества. Наименее малочислен класс, характеризующий пиелозктазию левой почки.




Рисунок 2.2 - Распределение классов объектов третьей версии обученной модели нейросети

Оценка точности обучения нейросети и качества детектирования объектов на МИ производилась после проведения процедуры обучения средствами самой нейросети. Для оценки качества детектирования объектов на изображениях нейросетями обычно применяются следующие показатели: для оценки локализации - IoU (Intersection over Union); для классификации объектов - Precision (точность), Recall (чувствительность); общая оценочная метрика для обнаружения объектов - mAP (mean Average Precision); для объединенной оценки точности и полноты модели – F1 [92], [93]. Для обобщенной оценки точности обучения нейросети и качества детектирования объектов на МИ был использован показатель F1. В последней версии обученной модели нейросети очевиден прогресс и значительное увеличение точности при обучении нейросети (рисунок 2.3).

Полученная модель нейросети с высокой точностью детектирует объекты заданных классов, что показано на матрице ошибок (рисунок 2.4).




Рисунок 2.3 - Сравнение точностей обучения трех версий модели нейросети




Рисунок 2.4 – Отсутствие ошибок в определении классов третьей версией модели нейросети YOLOv5m

Результаты обучения, полученные средствами самой нейросети, приведены на рисунке 2.5.




Рисунок 2.5 – Результаты обучения модели YOLOv5m

Как видно на графиках, данная версия обученной модели архитектуры YOLOv5m показала точность предсказания всех классов объектов 0,995.


Вероятность потерь объектов всех классов составила менее 0,005. При проверке точности обучения, выполняемой самой нейросетью в процессе обучения на валидационном датасете, вероятность потерь объектов всех классов составила менее 0,002.

Важным моментом при обучении нейросети является контроль за переобучением. В архитектуре нейросети YOLO разработчиками, начиная с версии YOLOv2, убраны слои «dropout» и внедрены слои «skip connection», которые предотвращают переобучение сети и делают ее более стабильной. Также для контроля за переобучением нейросети разработчиками рекомендовано следить за графиком ошибок тренировочного и валидационного процессов. О переобучении можно говорить, если график ошибок обучения продолжает снижаться, а график ошибок валидации начинает расти. Как видно на рисунке 2.4 на графиках «train/box_loss», «train/obj_loss», «train/cls_loss» происходит снижение ошибок обнаружения на тренировочном датасете как объектов, так и классов. В тоже время на графиках «val/box_loss», «val/obj_loss», «val/cls_loss» также наблюдается снижение ошибок обнаружения на валидационном датасете. Таким образом, можно сделать вывод что переобучения нашей модели нейросети YOLOv5m не произошло.


После обучения было выполнено апробация работы нейросети на МИ, полученных по данным КТ пациентов. Для апробации работы нейросети были взяты 100 изображений по КТ 24 пациентов, полученные с помощью программного модуля автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для детектирования, имеющие четные номера в имени файла, в то время как для обучения были использованы изображения, имеющие нечетные номера в имени файла.

Результаты детектирования МИ были предоставлены специалистам клиники для дальнейшего анализа возможности применения данной обученной модели нейросети в системе поддержки принятия медицинских решений в урологии. Анализ показал наличие ошибок детектирования нейросетью объектов (рисунок 2.6). Наиболее частыми были следующие ошибки: объекты почек или камней не

детектировались, неправильная локализация объектов почек (рисунок 2.6а и 2.6б), петли кишечника и другие внутренние органы детектировались как почки (рисунок 2.6в и 2.6г), ребра и тазовые кости детектировались как камни (рисунок 2.6д и 2.6е).




а)



б)




в)



г)



д)



е)

Рисунок 2.6 – Ошибки детектирования объектов на МИ нейросетью YOLO

Указанные ошибки возникли в связи с тем, что нейронная сеть ищет на изображении объекты, совпадающие по форме и виду с изображениями определенного класса, но нейросеть не может оценить, насколько правдоподобен ее вывод.

Основной причиной возникновения данных ошибок является отсутствие в алгоритме детектирования нейросети логики оценки локализации и взаимного расположения объектов на снимке внутренних органов человека. Для улучшения работы процедуры детектирования объектов на МИ, полученных по результатам компьютерной томографии внутренних органов человека, необходима разработка метрик и алгоритма нечеткой оценки результатов детектирования и классификации объектов нейросетью архитектуры YOLO.

2.2 Разработка метрик оценки качества обнаружения и классификации нейросетями объектов на медицинских изображениях

Для решения проблемы оценки качества полученных результатов детектирования объектов на МИ с помощью нейросети YOLO в работе предлагаются следующие метрики: **точность детектирования** DP (*detect precision*), **достоверность объекта** OR (*object reliability*) и **правдоподобие объекта** OV (*object veracity*) [94],[95].

Точность детектирования DP оценивает по форме результат работы модели нейросети после детектирования. Нейросеть при детектировании классифицирует объект с параметром *confidence* (уверенность). Обученная модель YOLO имеет набор метрик, которые характеризуют ее качество.

Для определения точности детектирования взят параметр *precision*, который характеризует точность детектирования объекта заданного класса. Точность детектирования DP объекта определяется значениями величин *confidence* для найденного объекта класса и *precision* для данного класса объектов и рассчитывается по формуле (2.1)

$$DP_i^k = C_i * P^k, \quad (2.1)$$

где DP_i^k – точность детектирования i -го объекта k -го класса, $i = 1..n$, n – количество детектированных объектов, $k = 1..m$, m – количество классов объектов в модели, в нашем исследовании $m=6$; C_i - уверенность при детектировании, которую выдает алгоритм распознавания YOLO для i -го объекта; P^k – точность модели по определению объектов k -го класса.

Данная метрика позволяет сочетать индивидуальную уверенность модели в конкретном обнаружении с ее общей способностью точно распознавать объекты данного класса, что дает более взвешенную и достоверную оценку точности детектирования конкретного объекта.

Однако для определения уверенности, что в полученном массиве находится объект заявленного класса недостаточно результатов детектирования по форме.

Достоверность объекта OR является дополнительной оценкой объекта класса «почка» по плотности с учетом границ значений плотности по Хаунсфилду для данного класса объектов. Вычисление достоверности выполняется после детектирования объекта нейросетью и трехмерной «сборки» объекта. Достоверность определяется по формуле (2.2)

$$OR_i = \frac{\sum_{j=1}^{V_i} r_j^k}{V_i}, \quad (2.2)$$

где OR_i – достоверность i -го объекта, $i = 1..n$, n – количество детектированных объектов почек класса k ; V_i – количество вокселей в объеме собранного i -го объекта; r_j^k – оценка принадлежности j -той точки – вокселя ($j = 1..V_i$) из объема массива к классу объектов (k) согласно шкале Хаунсфилда, которая определяется по формуле (2.3)

$$r_j^k = \begin{cases} 1, & H_{min}^k < h_j < H_{max}^k \\ 0 & \end{cases}, \quad (2.3)$$

где h_j – значение светимости j -го вокселя по Хаунсфилду; H_{min}^k – минимальное значение светимости для класса по Хаунсфилду; H_{max}^k – максимально значение светимости для класса по Хаунсфилду.

Значения r_j^k , присвоенное j -тому вокселю, указывает, соответствует ли плотность этого вокселя (измеренная в единицах Хаунсфилда) диапазону плотности, характерному для класса k почки.

Значение достоверности OR позволяет оценить результаты распознавания с учетом плотностных свойств объекта (рисунок 2.7). Значение достоверности $OR_j > 0,5$ позволяет отнести детектированный объект к заданному классу (рисунок 2.7, а). Однако при $OR_j < 0,5$ возможны как случаи обнаружения ложного результата,

например, петли кишечника (рисунок 2.7, б), так и случаи недостоверного значения для почек, в которых расположены крупные камни или большое количество камней (рисунок 2.7, в).




Рисунок 2.7 - Примеры оценки достоверности

Для оценки локализации объекта по отношению к внутренним органам человека предлагаются к применению две **метрики правдоподобия объекта OV** : **геометрический коэффициент правдоподобия GOV** и **плотностной коэффициент правдоподобия DOV** .

Геометрический коэффициент правдоподобия GOV предназначен для нечеткой оценки правильности расположения найденных объектов.

Для решения задачи определения правильности (правдоподобия) локализации и классификации объектов почек на изображении используется модель «облака правдоподобия» - Cl (Confidence cloud), которая создается после разметки, и представляет собой двумерный массив, в котором для соответствующей координаты (x, y) КТ-снимка записано значение функции принадлежности для k -го класса объектов (2.4)

$$Cl^k(x, y) = \mu^k(x, y) = \frac{1}{MC^k} \left(\frac{1}{N^k} \cdot \sum_{o=1}^{N^k} I_o^k(x, y) \right), \quad (2.4)$$

где $\mu^k(x, y)$ - значение функции принадлежности точки с координатами (x, y) геометрическому месту локализации k -го класса, формирующих модель облака правдоподобия Cl^k для k -го класса; N^k - количество размеченных объектов k -го класса; MC^k – максимальное значение функции, применяется для нормирования значений в модели облака правдоподобия в диапазоне $[0, 1]$; $I_q^k(x, y)$ - индикаторная функция, которая имеет значение (2.5)

$$I_o^k(x, y) = \begin{cases} 1, & (x, y) \in R_o^k(x_o, y_o, w_o, h_o), \\ 0 & \end{cases} \quad (2.5)$$

где R_o^k – область разметки объекта k -го класса, заданная параметрами x_o, y_o, w_o, h_o – координатами центра области, шириной и высотой ограничивающего объект прямоугольника.

В соответствии с формулами (2.4-2.5) были созданы «облака правдоподобия» для классов правая и левая почка (рисунок 2.8).




Рисунок 2.8 - «Облака правдоподобия» для правой и левой почек

Геометрический коэффициент правдоподобия GOV оценивает пересечение области ограничивающего прямоугольника почки и «облака правдоподобия» для точек с одинаковыми относительными координатами (рисунок 2.9).



Рисунок 2.9 - Наложение области детектирования правой почки и «облака правдоподобия» правой почки

Геометрический коэффициент правдоподобия для каждого найденного объекта определяется по следующей формуле (2.6)

$$GOV_i = \frac{\sum_{j=1}^{S_i} Cl^k(x,y) \times g_j^k(x,y)}{S_i}, \quad (2.6)$$

где GOV_i – геометрическое правдоподобие объекта, $i = 1..n^k$, n^k – количество детектированных почек k -го класса; $Cl^k(x, y)$ – берется из «облака правдоподобия», построенного заранее на основе формул 2.4 и 2.5; S_i – количество пикселей в области ограничивающего прямоугольника i -го объекта; $g_j^k(x, y)$ – оценка принадлежности j -го элемента ($j = 1..S_i$) из облака правдоподобия массиву пикселей детектированного i -го объекта заявленного класса (k) и определяется по формуле (2.7)

$$g_j^k(x, y) = \begin{cases} 1, & (x, y) \in R_i^k(x_i, y_i, w_i, h_i) \\ 0 \end{cases}, \quad (2.7)$$

где R_i^k – область i -го объекта k -го класса, заданная параметрами x_i, y_i, w_i, h_i – координатами центра области, шириной и высотой ограничивающего прямоугольника детектированного объекта.

Применение геометрического коэффициента правдоподобия GOV позволило оценить локализацию почек. Значение $GOV_i > 0,5$ позволяет классифицировать почку как заявленный класс.

Плотностной коэффициент правдоподобия DOV предназначен для плотностной оценки объектов камней и оценивает пересечение области почки и маску плотности i -го камня VR_i (рисунок 2.10).




Рисунок 2.10 - Наложение области детектирования почки и VR-маски камня

Плотностной коэффициент правдоподобия DOV применяется для локализации камней в почках и рассчитывается по формуле (2.8)

$$DOV_i = \frac{\sum_{j=1}^{V_i} d_j^i}{V_i}, \quad (2.8)$$

где DOV_i – плотностное правдоподобие i -го объекта камня, $i = 1..n^k$, n^k – количество детектированных камней k -го класса; V_i – множество точек VR_i -маски i -го камня, для которых $VR_j = 1$; d_j^i – оценка принадлежности j -той точки VR_i -маски i -го камня ($j = 1..V_i$) объему области собранной почки V^k ($k = 1..n^k$) и определяется по формуле (2.9)

$$d_j^i = \begin{cases} 1, & v_j^i \in V^k \\ 0 \end{cases}, \quad (2.9)$$

где v_j^i – j -й воксель из маски i -го камня, V^k – объем области собранной почки k -го класса.

Для камней при МКБ обязательным условием является локализация объекта «камень» внутри объекта «почка». Значение DOV_i для камня позволяет локализовать камень внутри почки только в случае $DOV_i \cong 1$ – камень полностью расположен внутри почки.

2.3 Разработка алгоритма нечеткой оценки результатов определения объектов на медицинских изображениях

Для оценки полученных результатов детектирования объектов на изображениях КТ предлагается следующий **алгоритм нечеткой оценки**, где оценка качества классификации объектов сводится к определению метрик близости найденного объекта к определенному классу по форме, локализации и плотности. Данные метрики формируют входной вектор $\vec{x}$. В предлагаемом алгоритме применяются нечеткие правила классификации, каждое из которых описывает один из видов классов в наборе данных. Постановка задачи нечёткой классификации объектов может быть сведена к классической задаче классификации объектов множества классов по кортежу нечетких переменных с помощью аппарата нечеткого вывода. В данных условиях эффективным является метод свертки

кортежей объектов изображения по классам с формированием нечеткой оценки принадлежности результатов, полученных после детектирования, к объектам заданных классов. Априорное правило является нечетким описанием в n -мерном пространстве свойств $\vec{x}$, последовательность правил является нечеткой меткой класса из множества правил M (2.10)

$$\vec{x} = [x_1, x_2, \dots, x_j, \dots, x_n], j = 1, 2, \dots, n, \quad (2.10)$$

здесь $\vec{x}$ – входной вектор оценок свойств объекта после детектирования и оценки по формулам (2.3 – 2.9); x_j – оценка j -го признака; n – обозначает число признаков.

Степень активации l -го правила из множества M вычисляется как (2.11)

$$\alpha_l(\vec{x}) = \prod_{j=1}^n A_{lj}(x_j), l = 1, 2, \dots, M, \quad (2.11)$$

где A_{lj} – функции принадлежности нечетких множеств, представленных нечеткими отношениями вывода l -го правила и входной компоненты x_j или предыдущего нечеткого правила.

Вывод классификатора определяется значением $g(l^*)$ в зависимости от класса объекта l^* , который имеет максимальную функцию активации α_l (2.12)

$$y = g(l^*), l^* = \arg(\max \alpha_l), 1 < l < M. \quad (2.12)$$

Степень уверенности в решении задана нормализованной степенью запуска правила (2.13)

$$Conf_{l^*} = \frac{\alpha_{l^*}}{\sum_{l=1}^M \alpha_l}. \quad (2.13)$$

Набор правил принадлежности A нечетких множеств нечеткого вывода для найденных объектов определенного класса были разработаны медицинскими экспертами клиники КММЦ.

Входной вектор параметров объекта для формирования нечетких правил представлен в таблице 2.2.

Для каждого параметра определены нечеткие категории (Low, Medium, High) с треугольными или трапециевидными функциями. Формулы функций принадлежности для ключевых параметров следующие (таблица 2.3).






Таблица 2.2 - Входной вектор параметров объекта

Параметр	Параметры	Значения
Класс объекта	левая почка	0
	камень	1
	правая почка	2
	левая почка увеличенная	3
	правая почка увеличенная	4
	коралловидный камень	5
Координата X	область правой почки	0,2-0,45
	область левой почки	0,55-0,70
Координата Y	область правой почки	0,2-0,80
	область левой почки	0,25-0,67
Площадь объекта ($w \times h$)	почка (норма)	0,04-0,09
	камень	0,00025-0,06
	почка (пиэлоктозная)	>0,8
Точность детектирования (DP)	низкая	0-0.4
	средняя	0.3-0.7
	высокая	0.6-1
Достоверность объекта (OR)	достоверен	0.5-1
	не достоверен	0-0.5
Геометрический коэффициент правдоподобия (GOV)	правдоподобен	0.5-1
	не правдоподобен	0-0.5
Плотностной коэффициент правдоподобия (DOV)	правдоподобен	0.9-1
	не правдоподобен	0-0.9

Таблица 2.3 – Функции принадлежности параметров

Метрика	Категории	Функции принадлежности
DP	низкая точность (L)	$\mu_L(DP) = \max(0, (0,3 - DP) / 0,3)$
	средняя точность (M)	$\mu_M(DP) = \max(0, \min((DP - 0,3)/0,3, (0,7 - DP)/0,3))$
	высокая точность (H)	$\mu_H(DP) = \max(0, (DP - 0,7) / 0,3)$
OR	неправдоподобен (L)	$\mu_L(OR) = \max(0, (0,5 - OR) / 0,5)$
	правдоподобен (H)	$\mu_H(OR) = \max(0, (OR - 0,4) / 0,6)$
GOV	неправдоподобен (L)	$\mu_L(GOV) = \max(0, (0,5 - GOV) / 0,5)$
	правдоподобен (H)	$\mu_H(GOV) = \max(0, (GOV - 0,4) / 0,5)$
DOV	неправдоподобен (L)	$\mu_L(DOV) = \max(0, (0,9 - DOV) / 0,9)$
	правдоподобен (H)	$\mu_H(DOV) = \max(0, (DOV - 0,8) / 0,2)$
Площадь объекта (Area)	почка (норма)	$\mu_K(Area) = \max(0, \min((Area - 0,04)/0,03, 1, (0,09 - Area)/0,03))$
	камень	$\mu_S(Area) = \max(0, \min((Area - 0,00025)/0,03, 1, (0,06 - Area)/0,03))$
	почка (пиэлоктозная)	$\mu_P(Area) = \max(0, (Area - 0,08) / 0,01)$

Графики указанных функций принадлежности $\mu(x)$ для метрик представлены на рисунках 2.11-2.15.

Рисунок 2.11 – График функции принадлежности $\mu(x)$ для DPРисунок 2.12 – График функции принадлежности $\mu(x)$ для ORРисунок 2.13 – График функции принадлежности $\mu(x)$ для GOVРисунок 2.14 – График функции принадлежности $\mu(x)$ для DOVРисунок 2.15 – График функции принадлежности $\mu(x)$ для Area

Нечеткие правила, предоставленные медицинскими специалистами, были разделены на две категории.

Правила для объектов на этапе детектирования.

α_1 : ЕСЛИ (Класс = 0) И (координата $X \in [0,55-0,70]$) И (координата $Y \in [0,25-0,67]$) И (Площадь = «почка (норма)») И (DP = Н) И (GOV = Н) ТО (объект - «левая почка»).

α_2 : ЕСЛИ (Класс = 2) И (координата $X \in [0,20-0,45]$) И (координата $Y \in [0,20-0,80]$) И (Площадь = «почка (норма)») И (DP = Н) И (GOV = Н) ТО (объект - «правая почка»).

α_3 : ЕСЛИ (Класс = 3) И (координата $X \in [0,55-0,70]$) И (координата $Y \in [0,25-0,67]$) И (Площадь = «почка (пиелоктозная)») И (DP = Н) И (GOV = Н) ТО (объект - «патологически увеличенная левая почка»).

α_4 : ЕСЛИ (Класс = 4) И (координата $X \in [0,20-0,45]$) И (координата $Y \in [0,20-0,80]$) И (Площадь = «почка (пиелоктозная)») И (DP = Н) И (GOV = Н) ТО (объект - «патологически увеличенная правая почка»).

α_5 : ЕСЛИ (Класс = 1) И (Площадь = «камень») И (DP = Н) ТО (объект - «камень»).

α_6 : ЕСЛИ (Класс = 5) И (Площадь = «камень») И (DP = Н) ТО (объект - «коралловидный камень»).

Правила для объектов после трехмерной сборки.

α_7 : ЕСЛИ (Класс = 0/3) И (OR = Н) ТО (объект - «левая почка»).

α_8 : ЕСЛИ (Класс = 2/4) И (OR = Н) ТО (объект - «правая почка»).

α_9 : ЕСЛИ (Класс = 1/5) И (DP = Н) И (DOV = Н) ТО (объект - «камень»).

Алгоритм нечеткой оценки результатов детектирования разбит на два этапа. Алгоритм объединяет жесткие проверки (анатомическая локализация) и нечеткие метрики (точность, размер, достоверность, правдоподобие).

Этап 1. Верификация расположения объектов почек и камней.

Данный этап выполняется во время анализа изображений нейросетью YOLO.

Входные данные:

а) Набор изображений (2D-срезы).

б) Обнаруженные на изображениях объекты $D_c = \{(o)|o \in O\}$ с параметрами:

– k — класс объекта ($K_{\text{прав}}$ - «правая почка», $K_{\text{лев}}$, -«левая почка», S_t - «камень»);

– $x_o, y_o \in [0,1]$ — относительные координаты центра объекта;

– $w_o, h_o \in [0,1]$ — относительные ширина и высота объекта;

– $\text{conf}_o \in [0,1]$ — уверенность детектирования.

Процедура:

1. Для каждого объекта o класса $k \in \{K_{\text{лев}}, K_{\text{прав}}\}$:

а) проверка условий $x_{\min}^k \leq x_o \leq x_{\max}^k$; $y_{\min}^k \leq y_o \leq y_{\max}^k$, если хотя бы одно условие не выполняется, удалить объект o из D_c ;

б) вычислить метрику точности DP_o^k по формуле (2.1);

с) вычислить площадь $\text{Area}_o^k = w_o \times h_o$;

д) рассчитать метрику правдоподобия GOV_o по формуле (2.6);

2. Для каждого объекта o класса $k \in S_t$ «камень»:

а) вычислить метрику точности DP_o^s по формуле (2.1);

б) вычислить площадь $\text{Area}_o^s = w_o \times h_o$;

3. Фаззификация метрик DP_o^k , GOV_o , Area_o^k , DP_o^s и Area_o^s в нечеткие переменные в соответствии с их функцией принадлежности.

4. Агрегация по правилам и дефаззификация. Степень активации правил вычисляется по формуле (2.11) как произведение степеней принадлежности.

5. Вывод и сохранение объектов - выбирается правило с максимальной степенью активации по формуле (2.12). Уверенность в выбранном решении определяется по формуле (2.13). Если правило активировано, оставить объект; иначе удалить из D_c .

6. Сохранить обновлённый словарь D_c .

Этап 2. Оценка плотности объектов почек и камней.

Данный этап выполняется после процедуры трехмерной сборки объектов почек и камней. На входе - массивы значений НУ (единицы Хаунсфилда) для:

а) камней;

б) почек - $K_{\text{лев}}, K_{\text{прав}}$.

Процедура:

1. Для каждого объекта почек $o \in \{K_{\text{лев}}, K_{\text{прав}}\}$ рассчитать показатель достоверности OR_o по формуле (2.2).
2. Для каждого объекта камня s вычислить коэффициент правдоподобия DOV_s по формуле (2.8).
3. Фаззификация входных параметров. Каждая метрика OR_o , DOV_s преобразуется в нечеткие переменные в соответствии с функциями принадлежности (таблица 2.3).
4. Агрегация по правилам и дефаззификация - степень активации правил вычисляется по формуле (2.11) как произведение степеней принадлежности.
5. Вывод и сохранение объектов - выбирается правило с максимальной степенью активации по формуле (2.12). Уверенность в выбранном решении определяется по формуле (2.13). Если правило активировано, оставить объект; иначе объекта удалить.

На выходе алгоритма на этапе 2 получаются числовые значения показателей точности, достоверности и правдоподобия, характеризующие оценку качества определения нейросетью объектов соответствующих классов на изображениях внутренних органов человека по найденным объектам правой и левой почек, по каждому из найденных объектов камней, а также обновлённые массивы данных почек и камней с подтверждёнными объектами для дальнейшей обработки.

Таким образом, данный алгоритм позволяет произвести оценку качества определения нейросетью объектов на изображениях внутренних органов человека, а также убрать объекты почек и камней, определенных с ошибками анатомического расположения.

2.4 Оценка качества определения объектов нейросетью на изображениях КТ

Оценка качества определения объектов нейросетью на изображениях КТ выполнялась до и после внедрения метрик и алгоритма нечеткой оценки медицинскими экспертами.

Для тестирования использована выборка по 100 изображений 24 пациентов, КТ которых не участвовали при создании обучающего датасета. Результаты распознавания в виде изображений, на которых выделены найденные объекты совместно с файлами, содержащими текстовое описание результатов детектирования, были представлены для анализа и оценки специалистам клиники КММЦ. Оценка распознавания проводилась следующим образом.

По каждому пациенту осуществлялся просмотр детектированных объектов по каждому классу объектов. Измерение точности результатов детектирования изображений проводились экспертами с использованием бинарного классификатора, который рассматривал положительные (positive) и отрицательные (negative) случаи. Положительный экземпляр классифицирует объект как член заявленного класса. Отрицательный экземпляр - классифицируется как объект, не принадлежащий к заявленному классу. Таким образом, формируются следующие количественные значения анализа экспертами результатов детектирования:

- True Positive (TP) — истинно положительные, что означает что объект детектирован и это правильно;
- False Positive (FP) — ложно положительные, что означает, что объект детектирован и это неправильно.

Мерой оценки точности при анализе экспертами являлась P (Precision) - доля верных результатов детектирования к общему числу найденных алгоритмом изображений, вычисляется по формуле (2.14)

$$P = \frac{TP}{TP+FP} , \quad (2.14)$$

где - TP — число верно определенных объектов, FP - число ошибочно определенных объектов.

В результате оценки экспертами-медиками были получены значения точности распознавания для всех классов объектов по пациентам. Далее были рассчитаны

средние значения точности распознавания по каждому классу отдельно и среднее по всем классам. Среднее значение точности определения по каждому классу вычислялась как среднее значение по всем пациентам по формуле (2.15)

$$P_{\text{ср}}^k = \frac{\sum P^k}{N^k}, \quad (2.15)$$

где N^k – число пациентов, у которых были классифицированы данные классы объектов.

Среднее значение общей точности определения по всем классам объектов вычислялась как среднее значение средних значений точности распознавания по каждому классу по формуле (2.16)

$$P_{\text{ср}}^{\text{общ}} = \frac{\sum P_{\text{ср}}^k}{K}, \quad (2.16)$$

где K – число классов объектов, $K = 6$.

Данные сводной оценки точности определения объектов на изображениях КТ до внедрения метрик и алгоритма оценки результатов определения объектов при детектировании нейросетью YOLO и после внедрения моделей и алгоритма приведены в таблице 2.4.

Таблица 2.4 - Оценка точности обученной модели по данным экспертов

Наименование класса объектов	Точность определения по данным экспертов до внедрения алгоритма и моделей	Точность определения по данным экспертов после внедрения алгоритма и моделей	Изменение точности
left_kidney	0,86	0,999	16%
stone	0,84	0,995	18%
right_kidney	0,95	0,995	5%
left_kidney_pieloectasy	0,69	0,998	45%
right_kidney_pieloectasy	0,67	0,999	49%
staghorn_stones	0,60	0,997	66%
Среднее по всем классам	0,77	0,997	30%

Проведенная оценка показала увеличение точности определения объектов нейросетью YOLOv5 после внедрения разработанных метрик и алгоритма нечеткой оценки результатов детектирования и классификации объектов на КТ в среднем по всем классом объектов на 30%.

Выводы второй главы

В данной главе представлена разработанная процедура обучения нейросети архитектуры YoloV5, была создана обучающая выборка, проведено обучение нейросети. Также описан метод оценки результатов детектирования и классификации объектов на медицинских изображениях с помощью метрик точности, достоверности, правдоподобия и алгоритма нечеткой оценки полученных результатов детектирования и классификации объектов на изображениях.

Разработанные метрики и алгоритм нечеткой оценки результатов детектирования и классификации объектов нейросетью архитектуры YOLOv5 на медицинских изображениях, полученных по результатам компьютерной томографии внутренних органов человека, позволяют классифицировать объекты в зависимости от их расположения и проекции изображения, избежать ошибок определения объектов, таким образом повысить точность результатов детектирования и классификации объектов.

В главе также проведена оценка качества определения нейросетью модели YOLOv5 до внедрения разработанного алгоритма нечеткой оценки результатов детектирования и классификации объектов на КТ, а также после внедрения данного алгоритма. Результаты детектирования обученной модели YOLOv5 до и после внедрения алгоритма нечеткой оценки были проанализированы и оценены специалистами клиники. Произведенный анализ показал рост качества определения нейросетью архитектуры YOLOv5 объектов почек и камней на изображениях внутренних органов человека в корональной проекции, полученных по результатам проведения КТ. До внедрения разработанных метрик и алгоритма оценки нейросеть допускала ошибки определения данных объектов на снимках, использование разработанных метрик и алгоритма нечеткой оценки позволили убрать обнаруженные ошибки определения объектов. Точность определения объектов на снимках, полученных по КТ, выросла в среднем по всем классам объектов на 30%.

Глава 3 Разработка процедуры трехмерной сборки объектов, алгоритма расчета параметров и визуализации найденных объектов по результатам детектирования на медицинских изображениях

3.1 Разработка алгоритма трехмерной сборки объектов почек и камней

Для использования данных об найденных на МИ с помощью нейросети архитектуры YOLO объектах в СППВР в урологии необходимо рассчитать параметры данных объектов, такие как масса найденных конкрементов, их линейные размеры, плотность и ее распределение по объему камня, выполнить трехмерную визуализацию найденных объектов почек и камней, провести процедуру трехмерной сборки объектов по параметрам, полученным после процедуры детекции. Для трехмерной сборки необходимо разработка алгоритма работы данной процедуры.

До проведения процедуры сборки при получении и сохранении изображений по КТ в имени файла кодируется номер среза по оси Y для удобства дальнейшего анализа, сборки и расчета параметров объектов. Далее выполняется детектирование изображений обученной моделью нейросети архитектуры YOLOv5. Результаты детектирования в виде набора файлов сохраняются в папке.

После выполнения этих операций далее необходимо выполнить процедуру послойной «сборки» (реконструкции) объектов камней и почек, которая происходит следующим образом. Входными данными для алгоритма является общий словарь обнаруженных объектов D , сформированный по итогам работы алгоритма нечеткой оценки результатов детектирования. Блок-схема алгоритма трехмерной сборки объектов почек приведена на рисунке 3.1. Выполняются следующие шаги.

Шаг 1. Считывание и формирование исходных данных.

Пусть F — множество файлов для обработки. Для каждого файла $f \in F$:

- Получаем множество срезов Sl_f .
- Для каждого среза $sl \in Sl_f$ определяем множество обнаруженных на нем объектов O_{sl} .

Каждый объект $o \in O_{sl}$ характеризуется следующим вектором параметров:

- $class_o \in K$ — класс обнаруженного объекта (например, $K_{\text{прав}}$ - «правая почка», $K_{\text{лев}}$ - «левая почка», S_t - «камень»).

- $x_o \in [0, 1]$ — относительная координата центра объекта по оси X;

- $z_o \in [0, 1]$ — относительная координата центра объекта по оси Z;

- $w_o \in [0, 1]$ — относительная ширина ограничивающего прямоугольника объекта;

- $h_o \in [0, 1]$ — относительная высота ограничивающего прямоугольника объекта;

- $conf_o \in [0, 1]$ — уверенность детектирования объекта.

Формируем общий словарь данных: $D = \{(sl, o) | sl \in Sl_f, o \in O_{sl}, f \in F\}$.



Рисунок 3.1 - Блок-схема алгоритма трехмерной сборки объектов почек

Шаг 2. Фильтрация объектов по классам и геометрическим признакам.

Для каждого класса $k \in \{K_{\text{лев}}, K_{\text{прав}}\}$:

1. Извлекаем множество объектов данного класса: $o_k = \{o \in D | class_o = k\}$.

2. Определяем область правдоподобия $GOV_k \subseteq [0,1] \times [0,1]$, соответствующую допустимым координатам центра (x, y) для объектов класса k .

3. Фильтруем объекты, центры которых принадлежат области GOV_k :

$$K_{k'} = \{o_k \in K_k | (x_o, z_o) \in GOV_k\}.$$

Шаг 3. Определение центрального среза почки.

Для каждого класса k :

1. Определяем площадь объекта: $Area_o = w_o \times h_o$.

2. Находим объект $o^c \in K_{k'}$, максимизирующий площадь и уверенность:

$$o^c = \operatorname{argmax}(Area_o, \operatorname{conf}_o).$$

Объект o^c считается центральным срезом выявленной почки класса k .

Шаг 4. Определение диапазона срезов и параметров почки.

Вычисляем параметры почки:

- координаты центра почки: (x_{o^c}, z_{o^c}) ;

- размеры ограничивающего прямоугольника для центрального среза: w_{o^c}, h_{o^c} ;

- координату y центрального среза: y_{o^c} ;

- номера первого и последнего срезов, где обнаружена почка: $s_{o^c}^{\min}, s_{o^c}^{\max}$.

Шаг 5. Вычисление координат трехмерного массива почки.

Для каждого класса определяем границы области почки в трехмерном пространстве:

- по оси X: $x_{start} = x_{o^c} - w_{o^c}/2$; $x_{end} = x_{o^c} + w_{o^c}/2$;

- по оси Z: $z_{start} = z_{o^c} - h_{o^c}/2$; $z_{end} = z_{o^c} + h_{o^c}/2$;

- по оси Y: $y_{start} = s_{o^c}^{\min}$; $y_{end} = s_{o^c}^{\max}$.

Шаг 6. Извлечение данных плотностей для почек.

Из трехмерного массива плотностей $V_{(x,y,z)}$ (яркость по Хаунсфилду), сформированного из DICOM данных КТ, извлекаем подмножество данных для каждой почки:

$$V^k = [V_{x_{start}:x_{end}}, V_{y_{start}:y_{end}}, V_{z_{start}:z_{end}}],$$

где V^k — трехмерный массив плотностей для почки класса k .

Шаг 7. Оценка качества определения почек.

На основе извлеченных параметров и данных выполняем оценку обнаружения объектов почек с использованием разработанной модели достоверности объекта OR^k . Если $OR^k \geq \tau$, где τ – установленный порог, то данный объект почки сохраняется, в противном случае удаляется.

Результатом работы алгоритма по сборке найденных объектов правой и левой почек, являются массивы светимости пикселей по Хаунсфилду для найденных правой и левой почек, которые сохраняются в файлы для удобства дальнейшего использования.

Подобным образом происходит работа алгоритма послойной «сборки» и формирование трехмерных массивов плотностей по Хаунсфилду для найденных конкрементов.

Данный алгоритм принимает на вход словарь D , представляющий информацию об объектах, полученный на шаге 1 алгоритма послойной сборки почек, а также данные о найденных параметрах для правой и левой почек $K_{\text{лев}}$, $K_{\text{прав}}$. Выполняются следующие шаги.

1. Выполняется сортировка данного словаря для объектов типа «камень» по принадлежности найденным на шаге 2 алгоритма послойной сборки почек объектам $K_{\text{прав}}$ - «правая почка» и $K_{\text{лев}}$ - «левая почка».

- Для каждого объекта типа «камень» $\{k \in St \mid o \in D\}$ получается набор координатных данных (x_o, z_o) на различных срезах.

- Создать пустые множества камней для левой и правой почек: $D_{\text{лев}} = \emptyset$, $D_{\text{прав}} = \emptyset$.

2. Определение принадлежности камня к почке.

Проверить принадлежность точки (x_o, z_o) областям почек $K_{\text{лев}}$ и $K_{\text{прав}}$ на центральном срезе почки o^c :

- если $(x_o, z_o \in K_{\text{лев}}(o^c))$, то объект o типа «камень» принадлежит левой почке: $D_{\text{лев}} = D_{\text{лев}} \cup \{o\}$;

- иначе, если $x_o, z_o \in K_{\text{прав}}(o^c)$, то объект o типа «камень» принадлежит правой почке: $D_{\text{прав}} = D_{\text{прав}} \cup \{o\}$;

- иначе, объект o типа «камень» отбрасывается (его координаты не находятся в пределах почек).

Таким образом формируются словари камней, принадлежащих отдельно правой почке и левой почке.

3. Группировка близко расположенных камней на разных слоях.

Для каждой почки $k \in \{K_{\text{лев}}, K_{\text{прав}}\}$:

3.1 Определение камней почки - рассматриваем множество D_k камней, назначенных почке k .

3.2 Группировка камней.

Установить порог близости δ .

Инициализировать пустой список групп $G_k = \emptyset$.

Для каждого камня $o \in D_k$:

- сравнить координаты (x_o, z_o) с камнями в существующих группах.

- если существует группа $g \in G_k$, такая что для любого камня $s' \in g$

$\sqrt{(x_o - x_{o'})^2 + (z_o - z_{o'})^2} \leq \delta$, то оставить камень в текущей группе g ;

- иначе, создать новую группу $g_{\text{new}} = \{o\}$ и добавить её в G_k .

3.3 Формирование списка групп.

В результате получаем список $G_k = \{g_1, g_2, \dots, g_n\}$, где каждая группа g_j содержит камни, расположенные близко друг к другу по пространству и слоям.

4. Определение центральных срезов и вычисление параметров камней.

Для каждой группы $g \in G_k$:

4.1 Вычисление суммарной плотности на срезах.

Для каждого среза s , на котором присутствуют камни из группы g :

- вычислить суммарную плотность: $Dens_{\text{total}}(s) = \sum_{p \in P_s(s)} HU(o)$, где $P_s(s)$

— множество пикселей объекта o типа «камень» на срезе s , $HU(o)$ — светимость (плотность) пикселя, принадлежащего камню на данном срезе sl .

4.2 Определение центрального среза.

Определить центральный срез sl_c : $sl_c = \max_s Dens_{total}(s)$.

4.3 Вычисление пространственных параметров.

На центральном срезе sl_c :

- определить координаты центра (x_0, z_0) из словаря D ;
- определить ширину w_o и высоту h_o ограничивающего прямоугольника

данного камня из словаря D .

5. Расчет координат для камня.

Вычислить координаты начала и конца камня по оси X по формулам

$$x_{start} = x_0 - w_o/2 ; x_{end} = x_0 + w_o/2 .$$

Вычислить координаты начала и конца камня по оси Z по формулам:

$$z_{start} = z_0 - h_o/2 ; z_{end} = z_0 + h_o/2 ,$$

где $x_{start}, x_{end}, z_{start}, z_{end}$ — максимальные и минимальные координаты по осям X и Z среди всех пикселей группы g на срезе sl_c .

Вычислить координаты начала и конца камня по оси Y по формулам:

$$y_{start} = y_{smin}, y_{end} = y_{smax},$$

где y_{smin} и y_{smax} — номера первого и последнего срезов для камня o .

6. Извлечь значения плотности HU из D_{HU} каждого камня o_g :

$$D_g = \{D_{HU_{x,y,z}} | (x, y, z) \in o_g\}.$$

7. Оценка плотностного коэффициента правдоподобия

Для камня o , назначенного почке:

- вычислить коэффициент правдоподобия DOV_o , основанный на модели плотности HU, для оценки нахождения камня внутри почки.

- если $DOV_o \geq \tau$, где τ — заранее установленный порог, то камень s подтверждается в наборе $D_{лев}$ или $D_{прав}$, в противном случае, камень s отбрасывается из набора.

Результатом работы алгоритма по сборке камней являются файлы с трехмерными массивами плотностей по Хаунсфилду для найденных конкрементов для правой и левой почек.

Разработанные алгоритмы трехмерной сборки объектов являются уникальными, впервые применяются для трехмерной реконструкции объектов типа «почка» и «камень» по данным КТ внутренних органов человека в разрабатываемой СППВР в урологии.

3.2 Разработка алгоритма расчета параметров объектов камней

В разрабатываемой СППВР в урологии необходимо выполнить расчет параметров найденных в почках конкрементов, который производится по следующему алгоритму.

Для расчета параметров камней в почках используются следующие параметры, полученные из текстовых файлов с метками и DICOM файлов:

- $x_0 \in [0, 1]$ — относительная координата центра камня по оси X;
- $z_0 \in [0, 1]$ — относительная координата центра камня по оси Z;
- $w_0 \in [0, 1]$ — относительная ширина ограничивающего камень прямоугольника;
- $h_0 \in [0, 1]$ — относительная высота ограничивающего камень прямоугольника;
- x, y, z - количество точек по осям X, Y, Z;
- x_{thin}, y_{thin} - толщина среза по координатам X и Y, z_{thin} - расстояние между срезами по координате Z.

1. Расчет размеров камня.

Вычисляется размер камня по оси X по формуле (3.1)

$$Length = x \times w_0 \times x_{thin} \quad (3.1)$$

Вычисляется размер камня по оси Z по формуле (3.2)

$$Height = z \times h_0 \times z_{thin} \quad (3.2)$$

Вычисляется размер камня по оси Y по формуле (3.3)

$$Thickness = (y_{end} - y_{start}) * z_{thin} \quad (3.3)$$

где y_{start}, y_{end} — номера срезов (первый и последний) КТ, где был обнаружен данный камень.

4. Расчет объема камня.

Для расчета объема камня необходимо сначала вычислить объем одного вокселя как произведение толщины среза по координатам X и Y на расстояние между срезами по координате Z (3.4)

$$V_{vox} = x_{thin} * y_{thin} * z_{thin}, \quad (3.4)$$

где V_{vox} – значение объема одного вокселя, x_{thin}, y_{thin} – толщины среза по координатам X и Y , z_{thin} – расстояние между срезами по координате Z .

Объем камня $V_{кам}$ вычислялся путем суммирования объемов всех вокселей в камне по трем осям координат (3.5)

$$V_{кам} = \sum_0^I \sum_0^J \sum_0^K V_{vox}, \quad (3.5)$$

где I, J, K – количество вокселей по осям x, y, z соответственно.

5. Расчет плотности камня.

Для расчета физической плотности камней для определения массы камня была использована следующая формула (3.6) [96]

$$\rho = HU \times 0,000485 + 1,539, \quad (3.6)$$

где HU – значение светимости вокселя камня по Хаунсфилду (HU), по данным компьютерной томографии.

Значение плотности вычислялось для каждого вокселя, принадлежащего объёму камня.

Масса камня m рассчитывалась как произведение объема одного вокселя на сумму плотностей всех вокселей, принадлежащих объёму камня (3.7)

$$m = V_{vox} \times \sum_{i=0}^I \sum_{j=0}^J \sum_{k=0}^K \rho_{ijk}, \quad (3.7)$$

где m – масса камня, ρ_{ijk} – значение плотности текущего вокселя в объёме камня.

Алгоритм расчета параметров объектов камней является новым, впервые применяется для расчета параметров объекта типа «камень» по данным КТ внутренних органов человека, данным, полученным после трехмерной сборки объектов после детектирования МИ нейросетью YOLOv5.

3.3 Разработка алгоритма трехмерной визуализации объектов почек и камней

Для использования в разрабатываемой СППВР в урологии трехмерной визуализации найденных необходима разработка алгоритмов визуализации. Алгоритмы 3D визуализации объектов камней были разработаны и реализованы в виде функции $F1$ формирования воксельной 3D модели камня и функции $F2$ 3-мерной интерактивной реконструкции камня.

На вход функции $F1$ формирования воксельной 3D модели камня передается трехмерный массив светимостей камня по Хаунсфилду, сформированный в результате предварительной обработки данных, полученных при детектировании объектов на изображениях и массива данных, полученного из DICOM-файлов. Также в функцию передаются такие параметры объектов, как: расстояние между слоями изображений по координате Z , расстояния между пикселями изображений по координатам X и Y , угла обзора и цветовая схема для окрашивания элементов вокселей. Функция $F1$ формирует объект, представляющий из себя объемный вид камня, полученный из сформированных вокселей с сохранением пропорций и геометрии найденного объекта (рисунок 3.2).




Рисунок 3.2 - Воксельная 3D визуализация камня

Кроме воксельной визуализации, осуществляется построение 3-мерной интерактивной визуализации камня. Визуализация 3-мерной модели осуществляется с послойным окрашиванием изменением светимости элементов камня по Хаунсфилду. На вход функции $F2$ 3-мерной интерактивной визуализации камня передается 3-хмерный массив светимостей элементов камня. Кроме того, входящими параметрами для функции являются расстояние между слоями

изображений по координате Z , расстояния между пикселями изображений по координатам X и Y . Функция $F2$ формирует объект, представляющий из себя объемный вид камня с сохранением пропорций и геометрии найденного объекта и выводом в отдельное окно (рисунок 3.3).




Рисунок 3.3 - 3-мерная интерактивная реконструкция камня

Реконструкция 3-мерной модели почки осуществляется функцией $F3$, реализующей послойное окрашивание процесса изменения светимости элементов камня по Хаунсфилду. На вход функции $F3$ передается 3-мерный массив светимостей элементов почки. Кроме того, входящими параметрами для функции являются расстояние между слоями изображений по координате Z , расстояния между пикселями изображений по координатам X и Y . Функция $F3$ формирует объект, представляющий из себя объемный вид почки с сохранением пропорций и геометрии найденного объекта и выводом в отдельное окно. Характерной особенностью работы функции является цветовое яркое выделение объектов «камень» на фоне объекта «почка» (рисунок 3.4).




Рисунок 3.4 - 3-мерная интерактивная реконструкция почки

Выводы третьей главы

В данной главе были разработаны алгоритмы послойной «сборки» объектов почек и камней. Также проведена разработка алгоритма расчета параметров для камней: линейных размеров, объема, массы камня. Кроме того, разработана процедура трехмерной воксельной визуализации камня, позволяющая визуализировать распределение плотности камня по его объему. Также разработаны алгоритмы 3-мерной интерактивной визуализации объектов камней и почек.

Разработанные алгоритмы реконструкции, расчета параметров камней и визуализации трехмерных объектов почек и камней по данным, полученным после детектирования нейросетью 2D объектов на медицинских изображениях, позволяют выполнить восстановление (сборку) объектов почек и камней, рассчитать физические параметры камней (линейные размеры, масса, плотность), также осуществить их трёхмерную и плоскостную визуализацию. Разработанные алгоритмы трехмерной сборки и визуализации объектов почек и камней являются уникальными, были применены в СППВР в урологии [97].

Глава 4 Разработка системы поддержки принятия врачебных решений в урологии с применением компьютерного зрения в урологии

4.1 Разработка требований к системе поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения

Система поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения предназначена для применения в лечебно-профилактических учреждениях (клинических многопрофильных центрах, больницах) как имеющих комплексы компьютерной томографии, так и не имеющих их. Разрабатываемая СППВР в урологии должна выполнять следующие функции [98], [99]:

- чтение первичных медицинских данных, полученных в результате компьютерной томографии;
- формирование набора изображений (датасета) для распознавания с помощью нейронной сети заданных классов объектов в области урологии;
- распознавание с помощью нейронной сети заданных классов объектов в области урологии, с использованием алгоритма оценки правдоподобия найденных объектов;
- первичная оценка точности, правдоподобия и достоверности результатов распознавания, определения параметров найденных объектов - координаты, размеры, плотность камней и патологических образований;
- анализ результатов распознавания и расчета параметров (размер, плотность, координаты) заданных медицинских объектов, характеризующих выбранную патологию, и принятие решений в урологии на основе экспертной системы, построенной на знаниях медицинских экспертов с использованием механизма нечеткого вывода;
- 3D – визуализация детектированных объектов с учетом параметров и распределения плотности объектов для планирования хирургических операций.

Количественные параметры, определяющие выполнение системой своих функций:

- точность обученной модели для детектирования - общая - не менее 0,97, не менее 0,95 по объектам;

- минимальное число изображений, полученных из первичных результатов DICOM файлов компьютерной томографии для дальнейшего распознавания на одного пациента – 100, с возможностью выбора данного параметра пользователем системы;

- минимальный размер изображений - соответствии с параметрами DICOM файлов, но не менее 200x200 пикселей;

- количество классов детектируемых объектов: до 20;

- количество объектов 3D – визуализации: до 10;

- количество форматов файлов изображений, с которыми может выполнять манипуляции система – 3 (“dicom”, “png”, “jpg”);

- количество пользователей, работающих одновременно, - 1 (одно рабочее место).

В СППВР используются следующие исходные и справочные данные:

- исходные данные - данные компьютерной томографии в формате DICOM файлов;

- справочные данные - шкала единиц Хаунсфилда, медицинские данные плотности разновидностей камней и образований в почках.

Выходные данные, получаемые СППВР в урологии в результате выполнения своих функций:

- изображения, полученные в результате обработки первичных данных компьютерной томографии;

- изображения, полученные в результате детектирования нейросетью медицинских изображений после предварительной обработки первичных данных компьютерной томографии с выделением найденных объектов;

- данные детектирования объектов с указанием координат и размеров обнаруженных объектов;

- изображения 3D – модели визуализации данных, полученных в результате компьютерной томографии;
- информация о найденных камнях в почках с указанием размера, объема, средней плотности, распределения плотности, веса.

4.2 Разработка алгоритма поддержки принятия врачебных решений выбору категории режима работы лазера для проведения процедуры лазерной литотрипсии

Лазерная литотрипсия является современным методом лечения мочекаменной болезни, лазер эффективно удаляет камни во всех участках мочевыводящей системы, позволяет вылечить пациентов при значительно небольшой травматичности самой операции. При данной процедуре в КММЦ применяется гольмиевый лазер с длиной волны лазерного излучения 2,1 мкм. Лазер имеет три режима, отличающихся длиной импульса. Дробление камней обычно осуществляется при энергиях импульсов от 0,6 до 2,5 Дж при частоте импульсов 8-15 Гц. Выбор врачом режима работы лазера при проведении процедуры лазерной литотрипсии определяется следующими факторами: временем, в течение которого произойдет разрушение камня, расположением камня внутри почки, его формой, значением плотности и распределением плотности по объему камня, близостью кровеносных сосудов, близостью тонких стенок внутренних органов. Каждому из режимов работы лазера соответствует определенное значение времени разрушения камня. Время разрушения камня зависит от массы камня, выбранной энергии и частоты работы лазера. Расчет времени разрушения камня гольмиевым лазером выполняется по следующей формуле (4.1) [100]

$$t_{\text{разр}} = \frac{m}{(\gamma * E * F)}, \quad (4.1)$$

где m – масса камня, грамм; γ - коэффициент гамма, равный 0,4; E - энергия импульсов лазера, Дж, задается в диапазоне от 0,6 до 2,4 с шагом 0,1; F – частота импульсов лазера, Гц, задается в диапазоне от 8 до 15 с шагом 1.

Для определения величин энергии и частоты импульсов лазера, а также для формирования рекомендаций, режимы работы лазерной установки медицинскими экспертами были распределены на следующие категории:

- режим для дробления осколков камней – характеризуется низким значением величины энергии импульсов лазера и низкой частотой импульсов,
- режим работы для камней с низкой плотностью – характеризуется низким значением величины энергии импульсов лазера и более высокими применяемыми частотами импульсов,
- режим работы при неудобных подходах инструмента к камню – характеризуется значением величины энергии импульсов лазера чуть ниже среднего и средними и чуть выше частотами импульсов лазера,
- оптимальный режим работы – применяется в большинстве процедур дробления камней и характеризуется средними значениями величин энергии и частоты импульсов лазера,
- режим работы в зоне высокой плотности камня – характеризуется значением энергии импульсов выше среднего, значения частоты импульсов находятся в диапазоне средних и чуть выше средних,
- режим работы с высоким риском нанесения травмы – характеризуется значениями энергии импульсов выше среднего и гораздо выше среднего, частотами импульсов выше среднего.

В соответствии с приведенной формулой (4.1) и данными, полученными от медицинских экспертов, с помощью MS Excel была разработана таблица экспериментальных расчетов времени разрушения камней в зависимости от частоты и энергии импульсов лазера.

Исходные данные для расчетов:

- величина гамма-излучения лазера – 0,4;
- частота импульсов, Гц – изменяется в диапазоне от 8 до 15 с шагом 1;
- энергия импульсов, Дж – изменяется в диапазоне от 0,6 до 2,4 с шагом 0,1.

На рисунках 4.1 – 4.3 приведены результаты расчетов времени для камней с массой до 1 грамма, до 10 грамм, свыше 20 грамм (мелкий, средний и крупный камни).




Рисунок 4.1 – Расчет времени разрушения камня массой 0,98 грамм во время лазерной литотрипсии при различных режимах работы лазера




Рисунок 4.2 – Расчет времени разрушения камня массой 9,7 грамма во время лазерной литотрипсии при различных режимах работы лазера




Рисунок 4.3 – Расчет времени разрушения камня массой 21,2 грамма во время лазерной литотрипсии при различных режимах работы лазера

Как видно на рисунках 4.1 - 4.3, диапазоны значения времени разрушения камней и, соответственно, значения величин энергии и частоты импульсов лазера окрашены в различные цвета, соответствующие установленным режимам работы лазера. Подбирая время разрушения камня, и руководствуясь данными пациента, врач сможет выбрать соответствующий режим работы лазера и установить значения величин энергии и частоты импульсов на лазерном аппарате.

Для формирования рекомендаций из-за неоднозначности определения режима работы лазерной установки был использован нечеткий логический вывод, который определяется матрицей нечеткого отношения B , в которой B_{ij} - значения нечеткого отношения (влияния) y_j из вектора факторов $\vec{y}$ и правила вывода r -го режима воздействия, которые являются нечеткими отношениями вывода r -го правила (режима) и входного вектора $\vec{y}$ [101], [102].

Априорное правило является нечетким описанием в n -мерном пространстве факторов $\vec{y}$, последовательность правил является нечеткой меткой класса из множества R режимов проведения операций (4.2)

$$\vec{y} = [y_1, y_2, \dots, y_j, \dots, y_n], j = 1, 2, \dots, n, \quad (4.2)$$

здесь n - обозначает количество факторов, определяющих выбор режима, которые формируют $\vec{y}$ - входной вектор.

Степень активации i -го правила из множества R вычисляется как (4.3)

$$\beta_i(\vec{y}) = \prod_{j=1}^n B_{ij}(y_j), i = 1, 2, \dots, R, \quad (4.3)$$

где B_{ij} - функции принадлежности нечетких множеств, которые являются нечеткими отношениями вывода i -го правила (режима) и входного вектора $\vec{y}$.

Вывод классификатора определяет режим, который имеет максимальную степень активации β_i (4.4)

$$z = v(i^*), i^* = \arg \max_{1 \leq i \leq R} \beta_i. \quad (4.4)$$

Степень уверенности в выбранном режиме задается нормализованной степенью запуска правила (4.5)

$$Conf_{i^*} = \frac{\beta_{i^*}}{\sum_{i=1}^R \beta_i}. \quad (4.5)$$

Для построения системы нечеткого выбора режима работы лазерной установки медицинскими экспертами клиники КММЦ были определены следующие правила выбора режимов работы с учетом входных факторов «энергии» (E), «частоты» (F), «размера камня» (S) и «плотности камня» (D).

Режимы работы были определены таким образом:

- R_1 - режим для дробления осколков камней,
- R_2 - режим работы для камней с низкой плотностью,
- R_3 - режим работы при неудобных подходах инструмента к камню,
- R_4 - оптимальный режим работы,
- R_5 - режим работы в зоне высокой плотности камня,
- R_6 - режим работы с высоким риском нанесения травмы,
- R_7 - малоэффективный режим,
- R_8 - малоэффективный не рекомендуемый режим.

Факторы, определяющие выбор режима лазерной установки, приведены в таблице 4.1.

Таблица 4.1 – Факторы, определяющие выбор режима лазерной установки

Фактор	Параметры	Значения	Описание
E - энергия импульсов лазера	минимальная низкая щадящая нормальная высокая очень высокая	0,6 Дж 0,7–1,1 Дж 1,0–1,6 Дж 1,5–1,9 Дж 1,8–2,2 Дж 2,1–2,4 Дж	минимальное значение для деликатных воздействий умеренная энергия стандартный режим интенсивное воздействие максимальная мощность
F – частота импульсов лазера	минимальная низкая щадящая нормальная высокая очень высокая	8 Гц 8–9 Гц 9–10 Гц 10–12 Гц 12–14 Гц 14–15 Гц	минимальное значение редкие импульсы умеренная частота стандартная частота частые импульсы максимальная частота
S - размер камня	мелкий средний большой	1-12 грамм 10-22 грамм > 20 грамм	маленькие фрагменты обычные камни крупные образования
D - плотность камня	низкая средняя высокая	160-320 HU 300-800 HU > 750 HU	мягкие камни умеренная плотность твердые камни

Для каждого фактора («энергия», «частота», «размер камня», «плотность камня») были определены функции принадлежности $\mu(x)$ в виде «трапецевидных» или «треугольных» кривых, учитывая перекрытия между градациями (таблицы 4.2-4.5). Используются следующие обозначения: a, b, c, d — точки излома линии, $\mu(x)$ — степень принадлежности значения x к диапазону $[0, 1]$.

Для «трапецевидной» кривой функция принадлежности определяется по формуле (4.6)

$$\mu(x) = \begin{cases} 0, x \leq a \\ \frac{x-a}{b-a}, a < x < b \\ 1, b \leq x \leq c \\ \frac{d-x}{d-c}, c < x < d \\ 0, x \geq d \end{cases} \quad (4.6)$$

Для «треугольной» кривой функция принадлежности определяется по формуле (4.7)

$$\mu(x) = \begin{cases} 0, x \leq a \\ \frac{x-a}{b-a}, a < x < b \\ \frac{c-x}{c-b}, b \leq x < c \\ 0, x \geq c \end{cases} \quad (4.7)$$

Таблица 4.2 – Функция принадлежности $\mu(x)$ для энергии импульсов лазера (E) (рисунок 4.4)

Градация	Тип функции	Параметры (a, b, c, d)	Описание
Минимальная	Точечная	$a = b = c = d = 0.6$	$\mu(x) = 1$, если $x=0.6$; иначе 0
Низкая	Трапедия	$a=0.6, b=0.7, c=1.1, d=1.2$	Линейный рост (0.6→0.7), плато (0.7–1.1), спад (1.1→1.2)
Щадящая	Трапедия	$a=0.9, b=1.0, c=1.6, d=1.7$	Рост (0.9→1.0), плато (1.0–1.6), спад (1.6→1.7)
Нормальная	Трапедия	$a=1.4, b=1.5, c=1.9, d=2.0$	Рост (1.4→1.5), плато (1.5–1.9), спад (1.9→2.0)
Высокая	Трапедия	$a=1.7, b=1.8, c=2.2, d=2.3$	Рост (1.7→1.8), плато (1.8–2.2), спад (2.2→2.3)
Очень высокая	Треугольная	$a=2.0, b=2.1, c=2.4$	Рост (2.0→2.1), спад (2.1→2.4)




Рисунок 4.4 – График функции принадлежности $\mu(x)$ для энергии импульсов лазера (E)

Таблица 4.3 – Функция принадлежности $\mu(x)$ для частоты импульсов лазера (F) (рисунок 4.5)

Градация	Тип ФП	Параметры (a, b, c, d)	Описание
Минимальная	Точечная	$a = b = c = d = 8$	$\mu(x) = 1$, если $x=8$; иначе 0
Низкая	Трапеция	$a=7, b=8, c=9, d=10$	Рост (7→8), плато (8–9), спад (9→10)
Щадящая	Трапеция	$a=8, b=9, c=10, d=11$	Рост (8→9), плато (9–10), спад (10→11)
Нормальная	Трапеция	$a=9, b=10, c=12, d=13$	Рост (9→10), плато (10–12), спад (12→13)
Высокая	Трапеция	$a=11, b=12, c=13, d=14$	Рост (11→12), плато (12–13), спад (13→14)
Очень высокая	Треугольная	$a=13, b=14, c=15$	Рост (13→14), спад (14→15)






Рисунок 4.5 – График функции принадлежности $\mu(x)$ для частоты импульсов лазера (F)

Таблица 4.4 – Функция принадлежности $\mu(x)$ для размера камня (S) (рисунок 4.6)

Градация	Тип ФП	Параметры (a, b, c, d)	Описание
Мелкий	Трапеция	$a=0, b=1, c=12, d=13$	Рост (0→1), плато (1–12), спад (12→13)
Средний	Трапеция	$a=9, b=10, c=22, d=23$	Рост (9→10), плато (10–21), спад (21→23)
Большой	Треугольная	$a=20, b=23, c=25$	Рост (21→22), плато (>22)

Рисунок 4.6 – График функции принадлежности $\mu(x)$ для размера камня (S)Таблица 4.5 – Функция принадлежности $\mu(x)$ для плотности камня (D) (рисунок 4.7)

Градация	Тип ФП	Параметры (a, b, c, d)	Описание
Низкая	Трапеция	a=100, b=160, c=320, d=400	Рост (100→160), плато (160–320), спад (320→400)
Средняя	Трапеция	a=250, b=300, c=800, d=850	Рост (250→300), плато (300–800), спад (800→850)
Высокая	Треугольная	a=700, b=750, c=1000	Рост (700→750), плато (>750)

Рисунок 4.7 – График функции принадлежности $\mu(x)$ для плотности камня (D)

Множество нечетких правил выбора режима было определено следующее.

Режим R_1 (дробление осколков):

β_1 - ЕСЛИ (E = низкая,) И (F = низкая) И (S = мелкий), ТО R_1 .

Режим R_2 (камни с низкой плотностью):

β_2 - ЕСЛИ (E = низкая/падающая) И (F = падающая/нормальная) И (D = Низкая),
ТО R_2 .

Режим R_3 (неудобные подходы):

β_3 - ЕСЛИ (E = падающая) И (F = нормальная/высокая) И (S =
средний/большой) И (D = средняя/высокая), ТО R_3 .

Режим R_4 (оптимальный режим):

β_4 - ЕСЛИ (E = нормальная) И (F = нормальная) И (S = средний) И (D = средняя), ТО R_4 .

Режим R_5 (высокая плотность камня):

β_5 - ЕСЛИ (E = высокая) И (F = нормальная/высокая) И (D = Высокая), ТО R_5 .

Режим R_6 (высокий риск травмы):

β_6 - ЕСЛИ (E = высокая/очень высокая) И (F = высокая/очень высокая) И (S = мелкий/средний), ТО R_6 .

Режим R_7 (малоэффективный):

β_7 - ЕСЛИ ((E = низкая) И (F = низкая)) ИЛИ ((S = большой) И (E < нормальная)), ТО R_7 .

Режим R_8 (не рекомендуемый):

β_8 - ЕСЛИ (E = минимальная) И (F = минимальная), ТО R_8 .

Для формирования рекомендаций по подбору значений частоты импульсов и энергии импульсов лазера в зависимости от режима дробления камней были определены следующие цвета, в которые будет произведено окрашивание ячеек значений времени разрушения в таблице расчета времени разрушения камней (таблица 4.6).

Таблица 4.6 - Цвета режимов для окрашивания ячеек в таблице расчета времени разрушения камней

Название режима	Цвет
Режим для дробления осколков камней	
Режим работы для камней с низкой плотностью	
Режим работы при неудобных подходах инструмента	
Оптимальный режим работы	
Режим работы в зоне высокой плотности камня	
Режим работы с высоким риском нанесения травмы	
Малоэффективный режим работы	
Малоэффективный режим работы – не рекомендовано к применению	

Алгоритм активации режима работы ($R_1 - R_8$) на основе входных параметров (E, F, S, D) реализуется следующим образом.

1. Расчет времени разрушения камня в соответствии с формулой (4.1) для каждого из значений энергии импульсов лазера и частоты импульсов из задаваемых диапазонов значений и соответствующего шага изменения каждой из этих величин.

Таким образом, для одного и того же камня получается матрица значений времени его разрушения.

2. Далее производится нечеткий анализ диапазонов значений величин энергии импульсов лазера и частоты импульсов, размеров и плотности камня в соответствии с установленными градациями значений для каждого рассчитанного значения времени разрушения. Определение степеней принадлежности параметров - фаззификация. Для каждого параметра вычисляется степень принадлежности к его нечетким градациям, используя функции принадлежности.

3. Активация правил. Для каждого правила $\beta_1 - \beta_8$ вычисляется степень его активации в соответствии с формулой (4.3).

4. Агрегация по правилам и дефаззификация. Выбирается правило с максимальной степенью активации по формуле (4.4). Уверенность в выбранном решении определяется по формуле (4.5).

5. Установление приоритета правил. Правила применяются в порядке убывания приоритета. Если активировано несколько правил, выбирается правило с высшим приоритетом, даже если его степень активации ниже (таблица 4.6). Приоритет правил: $R_8 \rightarrow R_6 \rightarrow R_5 \rightarrow R_4 \rightarrow R_3 \rightarrow R_2 \rightarrow R_1 \rightarrow R_7$. Таким образом, выбирается режим для каждого рассчитанного значения времени разрушения камня, начиная с наивысшего приоритета, остановка выбора режима производится на первом активированном правиле.


6. Окрашивание цвета ячейки выводимой таблицы в установленный цвет для активированного режима.

7. Вывод для всех допустимых режимов работы лазера со значениями настроек энергии и частоты в виде таблицы значений времени разрушения камня, ячейки таблицы окрашиваются определенным цветом, характеризующим каждый из режимов работы лазера в соответствии с установленной цветовой гаммой (рисунок 4.8).

Таблица 4.6 - Итоговая таблица приоритета режимов

Режим	Условия активации	Приоритет
R_8	$E = 0.6$ Дж, $F = 8$ Гц	1
R_6	$E \geq 1.8$ Дж, $F \geq 12$ Гц	2
R_5	$E \geq 1.8$ Дж, $D > 750$ НУ	3
R_4	$E = 1.5-1.9$ Дж, $F = 10-12$ Гц, $S = 10-22$ г	4
R_3	$E = 1.0-1.6$ Дж, $F = 10-14$ Гц, $S > 10$ г	5
R_2	$E = 0.7-1.6$ Дж, $D = 160-320$ НУ	6
R_1	$E = 0.7-1.1$ Дж, $F = 8-9$ Гц, $S = 1-12$ г	7
R_7	Все остальные комбинации	8

Частота, Гц	8.0	9.0	10.0	11.0	12.0	13.0	14.0	15.0
Энергия, Дж	8.0	9.0	10.0	11.0	12.0	13.0	14.0	15.0
0.6	0.51	0.46	0.41	0.37	0.34	0.32	0.29	0.27
0.7	0.44	0.39	0.35	0.32	0.29	0.27	0.25	0.23
0.8	0.38	0.34	0.31	0.28	0.26	0.24	0.22	0.2
0.9	0.34	0.3	0.27	0.25	0.23	0.21	0.2	0.18
1.0	0.31	0.27	0.25	0.22	0.2	0.19	0.18	0.16
1.1	0.28	0.25	0.22	0.2	0.19	0.17	0.16	0.15
1.2	0.26	0.23	0.21	0.19	0.17	0.16	0.15	0.14
1.3	0.24	0.21	0.19	0.17	0.16	0.15	0.14	0.13
1.4	0.22	0.2	0.18	0.16	0.15	0.14	0.13	0.12
1.5	0.2	0.18	0.16	0.15	0.14	0.13	0.12	0.11
1.6	0.19	0.17	0.15	0.14	0.13	0.12	0.11	0.1
1.7	0.18	0.16	0.14	0.13	0.12	0.11	0.1	0.09
1.8	0.17	0.15	0.14	0.12	0.11	0.11	0.1	0.09
1.9	0.16	0.14	0.13	0.12	0.11	0.1	0.09	0.09
2.0	0.15	0.14	0.12	0.11	0.1	0.09	0.09	0.08
2.1	0.15	0.13	0.12	0.11	0.1	0.09	0.08	0.08
2.2	0.14	0.12	0.11	0.1	0.09	0.09	0.08	0.07
2.3	0.13	0.12	0.11	0.1	0.09	0.08	0.08	0.07
2.4	0.13	0.11	0.1	0.09	0.09	0.08	0.07	0.07



Рекомендации по подбору режима работы лазера

Режим для дробления осколков камней	
Режим работы для камней с низкой плотностью	
Режим работы при неудобных подходах инструмента	
Оптимальный режим работы	
Режим работы в зоне высокой плотности камня	
Режим работы с высоким риском нанесения травмы	
Малоэффективный режим работы	
Малоэффективный режим работы - не рекомендовано к применению	

Рисунок 4.8 – Пример рекомендаций по выбору режима работы лазера

В результате хирург, планирующий операцию, может видеть режимы работы лазерной установки, время разрушения камня при выбранном режиме, величины энергии и частоты импульсов, характерные для различных режимов работы лазера.

4.3 Проектирование архитектуры системы поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения

Разработка концептуальной модели СППВР является важной частью жизненного цикла программного обеспечения, так как именно она первоначально определяет смысловую структуру системы [103]-[110].

Разрабатываемая СППВР на основе компьютерного зрения предназначена для применения в урологии, а именно для детектирования и распознавания объектов нейросетью YOLOv5 на снимках компьютерной томографии для проведения диагностики и лечения мочекаменной болезни. Концептуальная модель состоит из следующих элементов: диаграмма использования, диаграмма последовательности, диаграмма кооперации.

Диаграмма использования – это диаграмма, отображающая возможные сценарии использования, а также визуализирующая различные группы лиц или системы, которые взаимодействуют с различными функциями разрабатываемой системы. Основной целью данной диаграммы является описание функциональности и поведения разрабатываемой системы. Разработанная диаграмма использования разделена на 4 блока: блок «Получение информации», блок «Хранение данных», блок «Обработки данных» и блок «Обучения нейронной сети». В диаграмме были задействованы актеры (пациент, КТ томограф, врач, медицинский сотрудник, сотрудник клиники, общая база данных и база данных уролога), которые являются внешними сущностями по отношению к действиям, которые связаны с блоками системы. Блоки, отвечающие за получение и обработку данных, показаны на рисунке 4.9. Полный вид диаграммы приведен в приложении А.




Рисунок 4.9 - Диаграмма использования (часть 1)

Блок «Получение информации» отвечает за внутреннюю работу медицинского учреждения и получению данных с КТ томографа и непосредственно связан с блоком «Хранения информации». Блок «Обработки информации» представляет собой визуализацию работы разрабатываемой системы и связан с блоком «Обучения нейронной сети». Блоки, отвечающие за хранение данных и обучение нейронной сети, показаны на рисунке 4.10.




Рисунок 4.10 - Диаграмма использования (часть 2)

Диаграмма последовательности описывает поведенческие аспекты разрабатываемой системы и рассматривает взаимодействие экземпляров во времени (наглядно отображает временной аспект взаимодействия). Разработанная диаграмма последовательности отображена на рисунке 4.11 и в Приложении Б.




Рисунок 4.11 - Диаграмма последовательности

Диаграмма кооперации предоставляет возможность лучше понять связи между экземплярами разрабатываемой системы. Важной характеристикой диаграммы является возможность графически представить не только порядок взаимодействия, но и все структурные отношения между экземплярами, участвующими в этом взаимодействии. Разработанная диаграмма кооперации отображена на рисунке 4.12.

Данные диаграммы предназначены для упрощения процесса разработки, так как они позволяют лучше понимать требования, предъявляемые к системе.




Рисунок 4.12 - Диаграмма кооперации

Работа разрабатываемой СППВР в урологии сводится к выполнению следующих этапов (рисунок 4.13).

Этап считывания данных. На данном этапе производится чтение файлов из каталога, где хранятся данные КТ в формате DICOM файлов, производится анализ служебной информации о количестве серий в каталоге, количестве снимков в серии, пользователь (врач) выбирает нужную серию снимков. После выбора серии осуществляется собственно чтение массива светимостей внутренних органов по HU в той области, где могут располагаться почки; формирование и коррекция изображения в корональной проекции, сохранение набора изображений в папку на диск.




Рисунок 4.13 – Этапы работы СППВР

Этап поиска объектов на МИ. На данном этапе программными средствами нейросети YOLOv5 выполняется поиск объектов на каждом изображении внутренних органов человека в корональной проекции, полученных на этапе считывания данных. Также на данном этапе выполняется оценка точности и правдоподобия определения объектов правой и левой почек в соответствии с разработанными метриками точности DP и геометрического коэффициента правдоподобия GOV . Сохраняются объекты, значения метрик которых соответствуют заданным критериям. Таким образом на данном этапе сохраняются массивы обнаруженных на МИ объектов.

Этап сборки и визуализации объектов. На данном этапе выполняется послойная трехмерная сборка объектов правой и левой почек в соответствии с разработанным алгоритмом послойной сборки. Выполняется оценка достоверности объектов почек в соответствии с разработанной метрикой OR . Сохраняются объекты, показатель OR которых соответствуют заданной величине. Также выполняется послойная трехмерная сборка объектов камней. После сборки осуществляется оценка правдоподобия каждого из объектов камней на принадлежность правой либо левой почке по разработанной метрике плотностной оценки правдоподобия DOV . Оставляются только те объекты камней, показатель

плотностного коэффициента правдоподобия которых соответствует заданному значению. После этого выполняются расчеты параметров объектов камней, их 2D и 3D визуализация, также трехмерная интерактивная визуализация объектов почек.

Этап формирования рекомендаций. На данном этапе сначала выполняется расчет времени разрушения каждого камня в зависимости от его массы и значений энергии и частоты лазерной установки. На основе расчетов формируется таблица значений времени разрушения, ячейки которой окрашиваются в цвета, соответствующие режимам работы лазерной установки при проведении процедуры лазерной литотрипсии. Также выполняется формирование документа, в котором сохраняются данные о найденных объектах камней, с их трехмерной визуализацией, таблицей рассчитанных параметров, таблицей с рекомендациями по выбору значений энергии и частоты работы лазерной установки для разрушения камня.

Разработанная система поддержки принятия медицинских решений в области урологии состоит из следующих программных модулей: модуль по автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для детектирования, модуль по детектированию объектов на изображениях результатов компьютерной томографии, модуль по анализу результатов детектирования объектов, расчету параметров объектов, модуль по 3D – визуализации объектов по результатам детектирования, модуль поддержки принятия решений на основе экспертной системы, модуль формирования датасета. Связи между модулями системы представлены на рисунке 4.14.

Главный модуль системы связан с модулем формирования интерфейса системы, где происходит построение графического интерфейса и настройка основных глобальных переменных системы. Из модуля формирования интерфейса у пользователя есть возможность вызвать на выполнение следующие модули: модуль первичной обработки результатов КТ и формирования набора изображений для детектирования, модуль просмотра изображений и детектирования объектов на изображениях, модуль анализа результатов детектирования объектов на изображениях и расчета их параметров, модуль настройки параметров системы.




Рисунок 4.14 - Связь между модулями в системе поддержки принятия медицинских решений в области урологии

Вызов из модуля формирования интерфейса на выполнение модулей по анализу результатов детектирования и расчету параметров и модуля по 3D – визуализации объектов пользователем отдельно не предусмотрен. Из модуля формирования интерфейса пользователю предоставляется на выбор выполнение модуля настройки параметров системы, модуля первичной обработки результатов КТ и формирования датасета для детектирования, модуля детектирования объектов на изображениях, модуля анализа результатов детектирования и расчета параметров объектов.

4.4 Разработка программных модулей системы поддержки принятия врачебных решений в урологии с использованием технологий компьютерного зрения

Главный модуль системы вызывается на выполнение интерпретатором языка Python из основного каталога системы поддержки принятия медицинских решений

в области урологии и состоит из двух функций – функции вызова чтения настроек переменных системы и функции вызова модуля формирования интерфейса системы.

Блок-схема алгоритма работы модуля приведена на рисунке 4.15.




Рисунок 4.15 - Алгоритм работы главного модуля системы

Алгоритм работы данного модуля формирования интерфейса следующий.

1. Создание пользовательского графического интерфейса (GUI) - GUI предоставляет пользователю интерактивное меню, в котором доступны различные варианты действий.

2. Получение и обработка пользовательского ввода.

2.1 Выбор пользователем режима «Чтение данных КТ» - инициализация модуля предварительной обработки и генерации набора изображений для обнаружения объектов.

2.2 Выбор пользователем режима «Просмотр изображения и поиск камней»:

- а) Запуск функции просмотра изображений до обнаружения объектов.
- б) Если пользователь выбирает режим «Поиск камней», запускается модуль обнаружения объектов.
- с) Если пользователь выбирает режим «Выход», переход к шагу Создание пользовательского графического интерфейса.

2.3 Выбор пользователем режима «Просмотр детектированных изображений»:

- а) Запуск модуля просмотра изображений.
- б) Если пользователь выбирает режим «Расчет параметров камней», запускается модуль анализа результатов обнаружения объектов и расчета их параметров.
- с) Если пользователь выбирает режим «Выход», осуществляется переход к шагу «Создание пользовательского графического интерфейса».

Разработанный алгоритм модуля был реализован на языке Python 3.8. Вид интерфейса модуля представлен на рисунке 4.16.




Рисунок 4.16 - Вид главного меню модуля формирования интерфейса

Из модуля формирования интерфейса пользователем может быть вызван в работу модуль автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для дальнейшего детектирования.

Модуль автоматизации процесса первичной обработки предназначен для чтения данных, находящихся в DICOM файлах, полученных в результате

процедуры КТ осуществляет чтение первичных данных результатов компьютерной томографии внутренних органов, находящихся в заранее выбранной по умолчанию папке, в формате DICOM файлов.

Входными данными для модуля является путь к каталогу на диске, где хранятся исходные данные КТ в виде DICOM файлов. Выходными данными является путь к каталогу, куда происходит сохранение изображений, полученных из снимков КТ, и служебной информацией.

Блок-схема алгоритма работы модуля приведена на рисунке 4.17.

Алгоритм работы модуля следующий.

1. Выбор исходных данных.

Пользователь указывает каталог, содержащий файлы изображений в формате DICOM, полученных с помощью компьютерной томографии (КТ).

2. Импорт и обработка исходных данных.

- a) Открытие каталога DICOM-файлов.
- b) Извлечение метаданных, включая информацию о сериях снимков.
- c) Пользователь выбирает интересующую серию снимков.

3. Реконструкция изображений.

- a) Чтение выбранной серии снимков.
- b) Генерация трехмерного массива значений Хаунсфилда, представляющих плотность тканей и органов.
- c) Создание набора изображений в корональной плоскости.
- d) Сохранение изображений в форматах PNG или JPG в указанный каталог.

4. Сохранение обработанных данных.

Сохранение массива значений Хаунсфилда и метаданных для дальнейшего анализа параметров обнаруженных объектов.




Рисунок 4.17 - Алгоритм работы программного модуля первичной обработки результатов компьютерной томографии и создания набора изображений для детектирования

5. Просмотр изображений и запуск обнаружения объектов.

- а) Запуск функции просмотра изображений для предварительного контроля.
- б) Если пользователь выбирает режим «Детектирование объектов» - запускается на выполнение модуль по детектированию объектов на изображениях результатов компьютерной томографии.
- с) Если пользователь выбирает режим «Выход», управление передается модулю формирования пользовательского интерфейса.

В процессе формирования изображения происходит контроль числа получаемых изображений и размера получаемого изображения. Число получаемых изображений установлено в настройках системы, но не может быть меньше 100 (установлено в системе по умолчанию).

Размерность получаемого изображения рассчитывается на основании параметров данных DICOM файлов Rows, PixelSpacing, SliceLocation, которые получаются при чтении служебной информации из DICOM файла. После чтения данной служебной информации рассчитывается размер будущего формируемого изображения.

В процессе работы модуля производится улучшение яркости и контрастности изображения в соответствии со значениями ширины и центра окна визуализации, взятыми из dicom файлов [112]. По умолчанию значение ширины окна устанавливается -450 и центра окна визуализации -1500 для снимков КТ внутренних органов. Также системой выполняется производится контроль размерности получаемого изображения по X и Y координатам, и, если размер формируемого изображения менее, чем 200 x 200 пикселей, устанавливается стандартный размер изображения 200 x 200, изменяется размер формируемого изображения в соответствии с установленными параметрами.

В результате работы модуля на диске создается папка, куда сохранены изображения в формате «png» или «jpg» (зависит от настроек системы), служебные файлы с параметрами DICOM файлов, необходимые для проведения дальнейших

расчетов параметров объектов, а также текстовые файлы с описанием содержимого данной папки.

Модуль автоматизации процесса первичной обработки разработан с применением языка программирования Python 3.8.8 [111].

Модуль состоит из нескольких основных процедур и дополнительных функций. Основные процедуры:

- *readDicomFolder(dicom_path, images_path)* – главная процедура чтения данных из каталога, где хранятся DICOM файлы;
- *read_dicom_set(dicom_path)* – процедура собственной чтения DICOM файлов из каталога;
- *get_images_from_slice(data_array, images_path, slices, rows=512, columns=512, step=1)* – процедура получения изображения пациента в нужной проекции (корональной) из данных, хранящихся в DICOM файлах;
- *save_slice_to_image(image_name, slice_array)* – процедура обработки и сохранения отдельного изображения на диск;
- *get_dicom_path()* – процедура получения имени каталога, откуда необходимо произвести чтение DICOM файлов;
- *get_images_path(start_folder)* – процедура получения имени каталога, куда необходимо сохранять выходные изображения.

Интерфейс модуля и результат его работы представлены на рисунке 4.18.

Модуль системы по детектированию объектов на изображениях результатов компьютерной томографии предназначен для детектирования на полученных ранее изображениях КТ пациента в корональной проекции заданных классов объектов:

- левая почка правильной формы – класс «left_kidney» - 0 класс;
- конкременты (камни) правильной формы – класс «stone» - 1 класс;
- правая почка правильной формы – класс «right_kidney» - 2 класс;
- патологически увеличенная левая почка – класс «left_kidney_pieloectasy» - 3 класс;
- патологически увеличенная правая почка – класс «right_kidney_pieloectasy» - 4 класс;

- большой камень сложной формы (коралловидной формы) - класс «staghorn_stones»- 5 класс.




Рисунок 4.18 - Вид интерфейсов работы модуля первичной обработки результатов КТ (а) и результат формирования набора изображений для детектирования (б)

Входными данными для работы модуля является путь к каталогу, где хранятся созданный с помощью модуля по автоматизации процесса первичной обработки результатов компьютерной томографии набор изображений для детектирования.

Выходными данными является путь к каталогу «Detect», куда происходит сохранение уже детектированных изображений и путь к каталогу «labels», где сохраняются текстовые файлы с информацией об обнаруженных объектах: кода класса объекта, координаты центра ограничивающего прямоугольника, высота и ширина объекта, уверенность распознавания объекта.

Программный код данного модуля основан на коде, представленном на сайте разработчика [78]. Модуль был модифицирован путем добавления программной

реализации авторского алгоритма нечеткой оценки правдоподобия детектирования и элементов графического интерфейса.

Модуль по детектированию объектов на изображениях результатов компьютерной томографии вызывается на исполнение из модуля по автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для детектирования, а также из модуля просмотра существующих изображений из папки на диске.

Для корректной работы модуля на вход модуля необходимо подать следующие основные параметры: путь к файлу с весами для модели обученной нейросети, имя папки с изображениями, с которыми необходимо провести операцию по детектированию заданного числа объектов, заданное значение уверенности, с которой будет происходить детектирование объектов.

Блок-схема алгоритма работы модуля приведена на рисунке 4.19. Алгоритм работы данного модуля следующий.

1. Ввод данных.

Пользователь указывает путь к каталогу, содержащему набор изображений, на которых необходимо обнаружить объекты, также путь к данному каталогу может быть передан из процедуры просмотра изображений перед детектированием (шаг 5 алгоритма работы модуля автоматизации процесса первичной обработки).

2. Обнаружение объектов.

- a) Модуль использует алгоритмы компьютерного зрения для обнаружения объектов на изображениях.
- b) Алгоритмы оценивают достоверность и точность обнаружения.
- c) Объекты, не соответствующие заданным критериям, исключаются из дальнейшего анализа.

3. Сохранение результатов:

- a) Модуль сохраняет служебную информацию об обнаруженных объектах.
- b) Сохраняются изображения с нанесенными границами найденных объектов.




Рисунок 4.19 - Алгоритм работы программного модуля детектирования объектов на изображениях результатов компьютерной томографии

4. Представление результатов.

Пользователю предлагается просмотр изображений с обнаруженными объектами.

5. Оценка качества обнаружения.

Модуль по детектированию объектов на изображениях результатов компьютерной томографии разработан с применением языка программирования Python 3.8.8.

Модуль состоит из следующих процедур:

- *detect_stones(detect_folder, save_conf=True)* – процедура получения параметров детектирования и вызова процедуры детектирования;
- *detect(opt)* – процедура предназначена для детектирования заданного количества классов объектов на изображении, процедура содержит авторский алгоритм оценки правдоподобия (п.3.3).

Модуль производит первичную оценку качества обнаружения и вычисляет метрики точности и полноты. Объекты, не соответствующие заданным критериям качества, исключаются из дальнейшего анализа.

Для оценки правдоподобия в модуль детектирования внедрен алгоритм и модели нечеткой оценки. Оценка правдоподобия обнаружения почек и камней на медицинских изображениях выполняется по следующему алгоритму.

1) Оценка правдоподобия почек.

- а) Оценка правдоподобия обнаруженных почек выполняется путем вычисления степени перекрытия между координатами обнаруженных объектов и координатами «областей правдоподобия» почек.
- б) Если координаты обнаруженного объекта не попадают в «облако правдоподобия», оценка правдоподобия равна нулю, и объект исключается из списка обнаруженных.

2) Оценка правдоподобия камней.

Для камней накладываются дополнительные ограничения.

1. Координаты обнаруженных объектов должны попадать в границы найденных и оставленных на шаге 1 почек, чтобы исключить ложное обнаружение костей.
2. Точность детектирования должна быть не ниже 0,65 (установленный медицинскими экспертами порог).
3. Если эти условия соблюдены, параметры обнаруженного камня записываются в файл с метками, а границы объекта отображаются на результирующем изображении.

В результате работы модуля создается набор изображений, на которых нанесены границы найденных объектов, текстовое описание к каждому изображению, куда занесены параметры детектированных объектов: класс найденного объекта, координата X , координата Y , размер по вертикали, размер по горизонтали, величина уверенности, с которой был определен данный объект. Если ни на одном изображении из папки не было обнаружено перечисленных выше объектов, то в конечной папке не будет итогового изображения и в папке с текстовыми файлами с метками соответствующего файла не будет. По окончании процедуры детектирования пользователь попадает в диалоговое окно, где происходит просмотр уже детектированных изображений, на которых уже нанесены границы найденных объектов и для которых имеются текстовые файлы с параметрами обнаруженных объектов.

Интерфейс модуля и результат его работы представлены на рисунке 4.20.

Модуль по анализу результатов детектирования объектов, расчету параметров объектов предназначен для выполнения послойной «сборки» объектов почек и камней, анализа и расчета параметров найденных объектов классов камней на детектированных изображениях. Модуль вызывается на выполнение из диалогового окна просмотра детектированных изображений модуля детектирования, а также из главного модуля системы. Блок-схема алгоритма работы модуля приведена на рисунке 4.21.




Рисунок 4.20 - Вид интерфейса просмотра изображений после детектирования объектов

Алгоритм работы данного модуля следующий.

- 1) Ввод данных - пользователь указывает каталог, содержащий детектированные изображения и файлы с метками, полученные при обнаружении объектов.
- 2) Извлечение данных из файлов с метками.
 - а) Модуль сканирует все файлы с метками и извлекает информацию о параметрах обнаруженных объектов.
 - б) Данные организуются в массивы для удобства хранения и обработки.
- 3) Определение центрального среза почки.
 - а) Для каждой почки (правой и левой) выбираются объекты с максимальными размерами (по горизонтали и вертикали) и наибольшей уверенностью обнаружения.
 - б) Эти объекты определяют центральный срез почки.



Рисунок 4.21 - Алгоритм работы программного модуля анализа результатов детектирования объектов, расчета параметров объектов

4) Формирование трехмерной модели почки.

- а) Из массивов данных извлекаются объекты, координаты которых находятся вблизи центрального среза почки.
- б) Определяются первый и последний срезы, на которых обнаружены объекты, принадлежащие почке.
- с) На основании этих данных формируются координаты для трехмерной модели почки.

5) Формирование массивов плотностей для найденных почек.

- 1) Из ранее созданного массива плотностей тканей по Хаунсфилду (созданного при обработке DICOM-данных) извлекаются значения, соответствующие координатам трехмерной модели почки.
- 2) Формируются 3-мерные массивы плотностей для каждой почки.

6) Оценка качества определения объекта класса «почка».

На основании полученных данных выполняется оценка точности, правдоподобия и достоверности определения объекта класса «почка».

7) Сохранение результатов - сохраняются созданные трехмерные модели почек.

Подобным образом происходит формирование трехмерных массивов плотностей для найденных конкрементов.

8) Определение центрального среза камня.

Для каждого камня определяется «центральный» срез, на котором суммарная плотность обнаруженных объектов максимальна.

9) Формирование трехмерной модели камня.

- а) Определяются первый и последний срезы, на которых обнаруживаются объекты, принадлежащие камню.
- б) Формируются границы трехмерного массива для показателей плотности камня.

10) Извлечение массива плотностей камня.

Из общего массива плотностей, полученных из DICOM-файлов, извлекаются значения для конкретного камня.

11) Определение принадлежности камня к почке - принадлежность камня к правой или левой почке определяется путем сравнения координат центрального среза камня с областями, соответствующими правой и левой почкам на том же срезе.

12) Сохранение результатов - массивы плотностей для каждого камня сохраняются.

13) Анализ результатов обнаружения и расчет параметров камней.

- а) Извлечение служебной информации. Из ранее сохраненного файла извлекается служебная информация, созданная модулем формирования набора изображений.
- б) Расчет параметров камней. Для каждого обнаруженного камня отдельно для правой и левой почек рассчитываются параметры.
- с) Оцениваются точность, правдоподобие и достоверность определения камней.

14) Сохранение результатов.

- а) Сохраняются рисунки с двухмерной и трехмерной визуализацией камней.
- б) Сохраняются текстовые файлы с рассчитанными параметрами.

15) Просмотр результатов - пользователю предлагается просмотреть информацию и данные о каждом обнаруженном камне.

16) Трехмерная визуализация объектов.

Модуль по анализу результатов детектирования объектов, расчету параметров объектов реализован с применением языка программирования Python 3.8.8 [113].

Модуль состоит из следующих основных процедур:

- *main(input_path)* – процедура формирования графического пользовательского интерфейса, вызова на обработку процедур формирования списка камней в каждой почке (левой и правой), процедуры вычисления параметров найденных камней;

- *calc_stone_parameters(index, kidney_position)* – процедура расчета параметров отдельного камня, находящегося в одной из почек;

- *stone_info(stone_list)* – процедура получения из всех файлов с метками параметров отдельного камня, необходимых для дальнейших расчетов размеров, плотности;

- *get_found_stones_param(index, kidney_position)* – процедура получения параметров отдельного камня в выбранной почке, необходимых для дальнейших расчетов размеров, параметров оценки точности, правдоподобия и достоверности для камня;

- *stone_clusterize(stone_dict)* – процедура «сборки» камней из всех файлов с метками, полученными при детектировании, оценка параметров;

- *get_kidney_array(kidney_list, light_array)* – процедура получения массива плотностей и параметров оценки точности, правдоподобия и достоверности для почки;

- *get_kidney_info(kidney)* – процедура получения данных по почке: координаты центра, высота, ширина, номер среза с максимальной площадью, индекс первого нахождения данного объекта, индекс последнего обнаружения объекта.

Также разработаны вспомогательные процедуры, обеспечивающие работу основных алгоритмов [114].

Для интерактивной трехмерной визуализации камней и почек пользователь может вызвать функции модуля по визуализации объектов.

Данный модуль представляет из себя набор функций по построению и визуализации 3-D модели конкрементов и почек, а также вспомогательных функций, необходимых для построения моделей: формирования воксельной 3-D модели камня; интерактивной 3-D визуализации объекта типа «камень»; интерактивной 3-D визуализации объекта типа «почка». Вызов функций на выполнение осуществляется из модуля по анализу результатов детектирования объектов, расчету параметров объектов. В процессе расчета параметров найденных объектов – камней происходит обращение к функциям модуля по 3D – визуализации объектов, где происходит построение 3-мерных моделей конкрементов, затем происходит формирование изображений моделей и сохранение их в файл на диске. Модуль не осуществляет формирование интерфейса, все указанные функции

выполняются путем их вызова из диалогового окна модуля по анализу результатов детектирования объектов, расчету параметров [113].

Блок-схема алгоритма работы модуля приведена на рисунке 4.22. Интерфейс модуля и результат его работы представлены на рисунках 4.23 – 4.25.

Пользователю из интерфейса модуля анализа результатов детектирования и расчета параметров объектов доступен вызов модуля поддержки принятия врачебных решений, который предназначен для расчета времени разрушения камней в соответствии с введенными параметрами гамма-лазера и рассчитанной массы камня, а также для создания документа, в котором содержится информация о найденных (детектированных) в почках камнях, их параметрах, графического представления в виде двухмерной реконструкции с указанием линейных размеров и шкалы плотности (светимости) по Хаунсфилду и воксельной 3-D реконструкции, таблица с рассчитанным временем разрушения камня, его графического представления, а также рекомендаций по подбору режима работы лазера для проведения лазерной литотрипсии.

В состав модуля поддержки принятия врачебных решений входят следующие основные функции: формирования графического интерфейса; установки конфигурации параметров расчета времени разрушения; функция выполнения расчета времени разрушения камней; функция создания документа в формате PDF файла, в котором сохраняется таблица расчета времени разрушения и её графическое представление.

Алгоритм работы модуля поддержки принятия врачебных решений следующий:

1. Формирование интерфейса - модуль формирует графический интерфейс с полями для ввода данных и отображения результатов.
2. Ввод данных - пользователь вводит параметры камня (масса) и лазера (энергия, частота, гамма).




Рисунок 4.22 - Алгоритм работы программного модуля по 3D – визуализации объектов по результатам детектирования




Рисунок 4.23 - Вид интерфейса после работы модуля анализа результатов детектирования объектов, расчета параметров объектов и модуля 3D – визуализации




Рисунок 4.24 - 3-хмерная интерактивная реконструкция камня




Рисунок 4.25 - 3-хмерная интерактивная реконструкция почки

3. Расчет времени разрушения камня - модуль использует введенные параметры для расчета времени разрушения камня. Расчет выполняется на основе модели, которая учитывает физические свойства камня и лазера.

4. Отображение результатов - модуль отображает рассчитанное время разрушения камня в графическом интерфейсе.

5. Формирование рекомендаций по лазерной литотрипсии:

- а) Модуль формирует рекомендации по подбору режима работы лазера на основе рассчитанного времени разрушения камня.
- б) Рекомендации отображаются в виде таблицы, в которой ячейки окрашены в цвета, соответствующие категориям режимов работы лазера.

6. Создание PDF-документа - модуль создает PDF-документ, содержащий таблицу с расчетом времени разрушения камня, графическое представление расчета и рекомендации по лазерной литотрипсии.

7. Вывод результатов - пользователю предоставляются рассчитанные результаты и рекомендации в графическом интерфейсе и в виде PDF-документа.

Блок-схема алгоритма работы модуля приведена на рисунке 4.26.

Модуль по поддержке принятия врачебных решений в урологии разработан с применением языка программирования Python 3.8.8.

В состав модуля входят следующие основные функции:

- `def start(config: Config)` – функция формирования графического интерфейса;
- `class Config` – установка конфигурации параметров расчета времени разрушения;
- `on_view_created(self)` – отрисовка интерфейса на экране;




Рисунок 4.26 - Алгоритм работы модуля поддержки принятия решений

- *on_calculate_clicked(self, values: InputValues)* – функция определения нажатия на кнопку выполнения расчетов;
- *_calculate(self, values: InputValues)* – функция выполнения расчета времени разрушения камней;
- *on_output_path_selected(self, path)* – функция создания документа в формате PDF файла, в котором сохраняется таблица расчета времени разрушения и её графическое представление.

В процессе работы модуля производится расчет времени разрушения камня в зависимости от его массы и установленных по умолчанию диапазонов работы лазера – значений энергии и частоты импульсов, а также в зависимости от величины шагов изменения этих величин и установленной величины гамма для лазера. Далее производится нечеткий анализ диапазонов значений величин энергии лазера и его частоты.

После проведения расчетов производится формирование таблицы с результатами расчетов, где значения рассчитанной величины времени помещается в соответствующую ячейку. После этого ячейки таблицы окрашиваются в соответствии с результатами нечеткого анализа диапазонов значений величин энергии лазера и его частоты и в соответствии с установленными цветами по таблице 4.2.

После проведения всех расчетов формируется интерфейс модуля. Интерфейс модуля представлен на рисунке 4.27. Интерфейс представляет собой поля ввода данных и кнопок, выполняющих действия по расчету и сохранению данных. В поле «гамма излучение» вводится значение величины интенсивности гамма-излучения лазера, по умолчанию равна 0,4. В поля «частота излучения лазера» вводятся начальное и конечное значение диапазона частот лазера, используемые во время выполнения операции лазерной литотрипсии, по умолчанию данная величина изменяется в диапазоне от 8 до 15 Гц с шагом изменения 1. В поле «энергия лазера» вводятся начальное и конечное значение энергии лазера, используемые во время выполнения операции лазерной литотрипсии, по умолчанию данная величина

изменяется в диапазоне от 0,6 до 2,4 Дж с шагом изменения 0,1. Все эти значения можно изменять при необходимости.




Рисунок 4.27 – Интерфейс расчета времени разрушения камней модуля поддержки принятия врачебных решений

В окне интерфейса также присутствует таблица с рассчитанными параметрами времени разрушения для конкретного камня. Ячейки таблицы раскрашены в соответствии с цветами режимов работы лазера, рекомендованных для использования при проведении операции литотрипсии. Под таблицей располагается наглядная визуализация рассчитанных величин времени разрушения камня, расположенных в таблице.

Также на интерфейсе присутствуют рекомендации по выбору режимов работы лазера в зависимости от массы камня, а также категорий режимов работы.

В поле «масса камня» передается рассчитанная величина массы найденного конкремента, этот параметр рассчитывается модулем по анализу результатов детектирования объектов, расчету параметров объектов.

Кнопка «Рассчитать» выполняет функцию перерасчета времени в зависимости от введенных параметров (которые могут быть изменены врачом-хирургом).

Кнопка «Сохранить» сохраняет рассчитанную таблицу со значениями времени разрушения камня в зависимости от введенных параметров и её графическую визуализацию в документ в формате PDF. Имя файла и его расположение задается пользователем.

Выбор режима работы лазера при проведении процедуры литотрипсии связан с массой камня, значением плотности его частей, местом нахождения камня. Врач, осуществляя подготовку операции по разрушению камней, выбирает режим работы, оптимальный или иной, в зависимости от данных пациента, по времени разрушения камня из ячейки он получает из данной таблицы величины энергии лазера и частоту его работы, которую можно установить на лазерном аппарате.

Также в программный модуль входят вспомогательные функции, обеспечивающие выполнение основных функций.

Программа по созданию документа в PDF формате с таблицами, содержащими параметры найденных в почках камней, и их графического представления состоит из функции формирования файла и функции вызова системных средств работы с файлами в формате PDF.

Функция *create_PDF(stones_dir_path, RS_params, LS_params, param_numpy)* осуществляет создание документа в формате PDF, внесение в документ данных об исследуемом пациенте, даты проведения процедуры КТ, даты поиска камней на изображениях, полученных по результатам КТ, информации о конкрементах, обнаруженных в правой и левой почках.

Система ППВР имеет возможность формирования обучающего датасета для YOLOv5 в виде модуля формирования датасета. Входящими параметрами для данного модуля являются имя каталога, где хранятся детектированные изображения, рассчитанные параметры камней для правой и левой почек, имя файла с параметрами проведенной процедуры КТ.

Алгоритм формирования набора изображений для обучения следующий.

1) Подготовка данных.

1. В главном меню выбрать «Формирование обучающего датасета».

2. Выбрать каталог с изображениями, полученными из DICOM данных пациента.
3. Просмотреть сформированные изображения.
4. В настройках поиска отключить сохранение уверенности поиска в файлах с метками.
5. Нажать «Поиск камней» для автоматического обнаружения камней на изображениях.
6. Нажать «Выход» из окна поиска камней.
7. В главном меню снова выбрать «Формирование обучающего датасета».
8. Выбрать папку с изображениями, полученными на предыдущем шаге.
9. Выбрать папку для сохранения обучающего датасета.

2) Разметка изображений.

1. Просмотреть изображения в диалоговом окне.
2. Выбрать класс объекта из списка справа.
3. Нажать «Добавить объект».
4. Использовать мышь для рисования ограничивающего прямоугольника.
5. Нажать клавишу «Пробел» или «Enter» для подтверждения разметки.
6. Закрыть окно разметки.
7. Повторить шаги 3–6 для добавления других объектов на изображении.
8. Повторить шаги 1–7 для всех изображений в наборе.

3) Удаление разметки.

1. Выбрать класс объекта из списка справа.
2. Нажать «Удалить объект».
3. Система удалит данные о разметке выбранного объекта из файла с метками.

4) Удаление изображения - нажать «Удалить» для удаления текущего изображения и файла с метками.

5) Завершение - после разметки всех изображений, обучающий датасет готов к использованию для обучения нейронной сети.

Данный алгоритм описывает процесс ручного создания обучающего датасета для нейронной сети, которая будет использоваться для автоматической сегментации медицинских изображений. Алгоритм предполагает разметку объектов (камней) на изображениях, полученных из DICOM данных, с помощью графического интерфейса. Процесс включает в себя добавление, удаление и редактирование разметки объектов. Интерфейс модуля представлен на рисунке 4.28.




Рисунок 4.28 - Вид интерфейса формирования датасета для обучения

Выводы четвертой главы

В данной главе проведена разработка алгоритмов для интеграции в систему поддержки принятия врачебных решений в урологии с применением компьютерного зрения.

Был разработан алгоритм поддержки принятия врачебных решений в урологии при планировании проведения процедуры лазерной литотрипсии. В алгоритме использован механизм нечеткого логического вывода из-за

неоднозначности выбора режима работы лазерной установки, связанной с оценкой врачом не только времени разрушения камня, но и субъективных факторов. В процессе работы алгоритма производится вычисление времени разрушения камня в зависимости от его массы, диапазонов изменения значений энергии и частоты лазера, формируется матрица значений времени разрушения. Далее формируются рекомендации в виде таблицы значений времени разрушения, определение режима работы лазерной установки для каждого найденного значения и окраски диапазонов этих значений в цвета, которые соответствуют заданным режимам разрушения камней.

Разработаны требования к СППВР, определена архитектура СППВР, определены назначение и функции модулей системы, спроектированы связи между модулями, определены входная и выходная информация для модулей системы, разработаны алгоритмы функционирования модулей, выполнена программная реализация модулей системы. Описание работы разработанной СППВР в урологии приведено в Приложении В. Система поддержки принятия врачебного решения позволяет сократить время на принятие решения врачом, избежать ошибок при выборе параметров работы лазерной установки по дроблению камней в почках.

Разработанные модули были реализованы в виде программных модулей, получены свидетельства на программы для ЭВМ (Приложение Д). Разработанная СППВР в урологии была протестирована совместно с представителями КММЦ, составлен протокол тестовых испытаний, работа системы была признана удовлетворительной. Протокол тестирования приведен в Приложении Д.

Система поддержки принятия решений позволит снизить временные затраты на проведение медицинских исследований, постановку диагноза и выбор врачебного решения при планировании операций и может быть адаптирована для решения иных диагностических задач, связанных с анализом и оценкой медицинских изображений.

Заключение

В рамках диссертационного исследования разработаны алгоритмы автоматизированного анализа КТ-изображений на основе технологий компьютерного зрения для создания интеллектуальной системы поддержки принятия решений в урологии при обработке данных медицинской визуализации. Проведен анализ современного состояния исследований по теме диссертации. Установлено, что в настоящий момент в отечественной медицинской практике системы поддержки принятия решений в урологии, основанные на методах компьютерного зрения, пока не получили широкого распространения ввиду того, что алгоритмы анализа медицинских изображений могут ошибаться из-за сложной анатомии объектов, вариабельности патологий и неоднозначности интерпретации результатов. Классические метрики оценки качества моделей не учитывают анатомическую реалистичность обнаруженных объектов, что снижает надежность систем в реальных клинических сценариях. Поэтому существует необходимость в разработке алгоритмов автоматизированного анализа КТ-изображений на основе технологий компьютерного зрения, создания и дальнейшего усовершенствования таких систем в урологии.

Основные результаты исследования могут быть сформулированы следующим образом:

1. Проведено исследование современного состояния применения МИС и СППВР с применением технологий компьютерного зрения в различных областях медицины, в том числе в урологии. Проведена оценка эффективности различных инструментов компьютерного зрения для анализа медицинских изображений. На основе проведенного исследования для решения задач поиска объектов на изображениях, полученных в результате компьютерной томографии внутренних органов человека, была определена нейросеть архитектуры YOLOv5.

2. Разработана процедура обучения нейросети YOLOv5, создана обучающая выборка, проведено обучение. Разработаны метрики оценки точности, достоверности и правдоподобия, а также алгоритм нечеткой оценки полученных результатов детектирования и классификации нейросетью объектов на

медицинских изображениях с использованием предлагаемых метрик. Разработанная методика оценки результатов детектирования и классификации объектов нейросетью YOLOv5 на медицинских изображениях, полученных по результатам компьютерной томографии внутренних органов человека, позволила избежать ошибок определения объектов, таким образом повысить точность результатов детектирования и классификации объектов. Проведена оценка качества определения нейросетью модели YOLOv5 до внедрения разработанного алгоритма нечеткой оценки результатов детектирования и классификации объектов на КТ, а также после внедрения данного алгоритма. Результаты проверки продемонстрировали существенное повышение точности определения объектов на КТ-изображениях внутренних органов человека в среднем на 30% по всем классам после внедрения разработанного алгоритма.

3. Разработаны алгоритмы трехмерной реконструкции, расчета параметров и 3D-визуализации объектов по результатам детектирования на медицинских изображениях. Разработанные алгоритмы реконструкции, расчета параметров камней и визуализации трехмерных объектов почек и камней по данным, полученным после детектирования нейросетью объектов на медицинских изображениях, позволяют выполнить восстановление объектов почек и камней, рассчитать физические параметры камней, также осуществить их трёхмерную и плоскостную визуализацию.

4. Разработан алгоритм поддержки принятия решений для врачей-урологов, оптимизирующий выбор параметров лазерной литотрипсии на этапе планирования операции. В алгоритме использован механизм нечеткого логического вывода из-за неоднозначности выбора режима работы лазерной установки, связанной с оценкой врачом не только времени разрушения камня, но и субъективных факторов. Алгоритм предоставляет наглядную визуализацию различных режимов фрагментации конкрементов, отображая рассчитанное время разрушения камня в зависимости от его массы, энергии и частоты лазерных импульсов, что существенно облегчает процесс принятия решения.

5. Разработана структура и алгоритмы системы поддержки принятия медицинских решений в области урологии. Разработанная система была реализована в виде программных модулей, получены свидетельства на программы для ЭВМ. Разработанная СППВР в урологии была протестирована совместно с представителями КММЦ, работа системы была признана удовлетворительной. Система поддержки принятия решений позволяет снизить временные затраты на проведение медицинских исследований, постановку диагноза и выбор врачебного решения при планировании операций и может быть адаптирована для решения иных диагностических задач, связанных с анализом и оценкой медицинских изображений.

Таким образом, все задачи, поставленные в работе, были решены успешно в полном объеме, цель диссертационной работы достигнута.

Разработанные метрики оценки и алгоритм нечеткой оценки результатов детектирования с помощью нейросетей объектов на медицинских изображениях, полученных по результатам КТ, а также алгоритмы реконструкции и расчета параметров объектов могут быть применены для других объектов. Разработанная СППВР с использованием технологий компьютерного зрения и методов нечеткой логики урологии может быть применена для первичной диагностики мочекаменной болезни человека. В дальнейшем система поддержки принятия врачебных решений может быть использована в составе автоматизированного рабочего места хирурга, уролога или радиолога, встроена в программно-аппаратные комплексы компьютерной томографии. Разработанная СППВР является уникальной, предоставляет врачам-урологам инструмент, позволяющий сократить время на постановку диагноза и принятия решения при планировании операций, а также значительно снизить риски осложнений за счет повышения точности принятого врачебного решения. Система может быть адаптирована для решения иных диагностических задач, связанных с анализом и оценкой медицинских изображений.

Список сокращений и условных обозначений

АРМ – автоматизированное рабочее место

ЕГИСЗ - Единая государственная информационная система в сфере здравоохранения

ИИ – искусственный интеллект

ИС – информационная система

КТ – компьютерная томография

ЛПУ – лечебно-профилактические учреждения

МИ – медицинские изображения

МИС – медицинская информационная система

МРТ – магниторезонансная терапия

НИИ – научно-исследовательский институт

СНС – сверточные нейронные сети

СППВР – система поддержки принятия врачебных решений

СППР – система поддержки принятия решений

Список литературы

1. Квашнина, Е. А. Медицинские информационные системы : учебное пособие / Е. А. Квашнина, Е. Е. Трубилина. — Новосибирск : НГТУ, 2023. — 104 с. — ISBN 978-5-7782-4928-8. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/404354> (дата обращения: 12.12.2024).
2. Полиданов, М. А. К вопросу о классификации медицинских информационных систем / М. А. Полиданов, И. С. Блохин // Modern Science. — 2020. — № 2-2. — С. 226-232.
3. Савельева, К. Е. История развития отечественных медицинских информационных систем / К. Е. Савельева // Научный дебют 2023 : Сборник статей IV Международного научно-исследовательского конкурса, Петрозаводск, 03 декабря 2023 года. — Петрозаводск: Международный центр научного партнерства «Новая Наука» (ИП Ивановская И.И.), 2023. — С. 73-77.
4. Кобринский Б. А. Системы поддержки принятия врачебных решений: история и современные решения // Методология и технология непрерывного профессионального образования. 2020. №4 (4). URL: <https://cyberleninka.ru/article/n/sistemy-podderzhki-prinyatiya-vrachebnyh-resheniy-istoriya-i-sovremennye-resheniya> (дата обращения: 12.12.2024).
5. Лопсан, А. А. Медицинские информационные системы: понятие, классификация, функции / А. А. Лопсан // Инновации. Наука. Образование. — 2021. — № 46. — С. 1404-1411.
6. Михеев, А. Е. Стратегия управления медицинскими услугами в медицинских информационных системах / А. Е. Михеев, О. А. Фохт, И. Л. Хайт // Менеджер здравоохранения. — 2022. — № S1. — С. 23-33. — DOI 10.21045/1811-0185-2022-S-23-33.
7. Карпов О. Э., Никуличев А. А., Пензин О. В., Субботин С. А., Андриков Д. А., Перфильев А. Е. Архитектура медицинских информационных систем нового поколения // Вестник Национального медико-хирургического Центра им. Н. И. Пирогова. 2019. №3. URL: <https://cyberleninka.ru/article/n/arhitektura-meditsinskih-informatsionnyh-sistem-novogo-pokoleniya> (дата обращения: 12.12.2024).

8. Реброва, О. Ю. Жизненный цикл систем поддержки принятия врачебных решений как медицинских технологий / О. Ю. Реброва // Врач и информационные технологии. – 2020. – № 1. – С. 27-37. – DOI 10.37690/1811-0193-2020-1-27-37.

9. Черных, Д. А. Обзор современных медицинских информационных систем. Основные подходы к проектированию медицинских информационных систем для отделений реанимации / Д. А. Черных // Научная инициатива: проблемы и перспективы внедрения инновационных решений : Материалы научно-практической конференции, Астрахань, 25–26 апреля 2024 года. – Астрахань: Астраханский государственный университет им. В.Н. Татищева, 2024. – С. 269-273.

10. Виноградский, В. Г. Анализ медицинских информационных систем / В. Г. Виноградский, В. Н. Бочкова // Заметки ученого. – 2021. – № 12-1. – С. 55-61.

11. Кельман, Т. В. Тенденции развития медицинских информационных систем / Т. В. Кельман, Д. Р. Коткова, Д. М. Марголис // Модели и методы повышения эффективности инновационных исследований : Сборник статей по итогам Международной научно-практической конференции, Омск, 09 июня 2024 года. – Стерлитамак: Общество с ограниченной ответственностью "Агентство международных исследований", 2024. – С. 110-113.

12. Проскуряков, А. В. Концепция медицинской информационной системы для решения задач диагностики заболеваний на основе верификации фрагментов медицинских биологических объектов / А. В. Проскуряков // Известия ЮФУ. Технические науки. – 2022. – № 5(229). – С. 244-257. – DOI 10.18522/2311-3103-2022-5-244-257.

13. Айдархан, О. Б. Применение искусственного интеллекта в медицинских информационных системах для повышения качества диагностики и лечения / О. Б. Айдархан, С. Гульжан // Интернаука. – 2024. – № 20-1(337). – С. 50-55.

14. Хрипунова, А. А. Информационные технологии в медицине и здравоохранении : учебно-методическое пособие / А. А. Хрипунова, Е. В. Максименко. — Ставрополь : СтГМУ, 2021. — 88 с. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/326282> (дата обращения: 16.12.2024). — Режим доступа: для авториз. пользователей.

15. Фролов, С. В. Системы поддержки врачебных решений в медицине / А.Ю. Куликов, О.А. Остапенко, Е.В. Стрыгина // Научный журнал. 2018. №9 (32). URL: <https://cyberleninka.ru/article/n/sistemy-podderzhki-vrachebnyh-resheniy-v-medicine> (дата обращения: 22.08.2024).

16. Малых, В.Л. Системы поддержки принятия решений в медицине // Программные системы: теория и приложения. 2019. №2 (41). URL: <https://cyberleninka.ru/article/n/sistemy-podderzhki-prinyatiya-resheniy-v-medicine> (дата обращения: 22.08.2024).

17. Румовская, С. Б. Интеллектуальные системы поддержки принятия решений в медицине: понятие, проблемы, подходы к разработке / С. Б. Румовская // Системы и средства информатики. – 2024. – Т. 34, № 2. – С. 107-122. – DOI 10.14357/08696527240208.

18. Рюмин, А. М. Перспективы развития систем поддержки принятия решения в клинической медицине / А. М. Рюмин // Каспий и глобальные вызовы : Материалы Международной научно-практической конференции, Астрахань, 23–24 мая 2022 года / Составители: О.В. Новиченко [и др.]. – Астрахань: Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования «Астраханский государственный университет», 2022. – С. 325-328.

19. Новые возможности искусственного интеллекта в медицине: описательный обзор / А. А. Литвин, И. О. Стома, Т. М. Шаршакова [и др.] // Проблемы здоровья и экологии. – 2024. – Т. 21, № 1. – С. 7-17. – DOI 10.51523/2708-6011.2024-21-1-01.

20. Шадеркин, И. А. Слабые стороны искусственного интеллекта в медицине / И. А. Шадеркин // Российский журнал телемедицины и электронного здравоохранения. – 2021. – Т. 7, № 2. – С. 50-56. – DOI 10.29188/2712-9217-2021-7-2-50-52.

21. Кривенко, М. П. Мягкие вычисления в задачах медицинской диагностики / М. П. Кривенко // Информатика и ее применения. – 2021. – Т. 15, № 2. – С. 52-59. – DOI 10.14357/19922264210208.

22. Искусственный интеллект в диагностике и лечении мочекаменной болезни / А. А. Пранович, А. К. Исмаилов, Н. А. Карельская [и др.] // Российский журнал телемедицины и электронного здравоохранения. – 2022. – Т. 8, № 1. – С. 42-57. – DOI 10.29188/2712-9217-2022-8-1-42-57.

23. Смирнова, Т. В. Практические кейсы применения искусственного интеллекта для анализа КТ-изображений / Т. В. Смирнова, Н. А. Филимонова // Университетская медицина Урала. – 2023. – Т. 9, № 1(32). – С. 45-48. – DOI 10.36361/24129445_2023_9_1_45.

24. Левенков К.О. Коровин Е.Н. Новикова Е.И. нейросетевое моделирование процесса выбора схемы лечения пациентов с хроническим пиелонефритом и мочекаменной болезнью. Моделирование, оптимизация и информационные технологии. 2018;6(4). Доступно по: https://moit.vivt.ru/wp-content/uploads/2018/10/LevenkovSoavtors_4_18_1.pdf DOI: 10.26102/2310-6018/2018.23.4.005

25. Галченков, А. С. Сервисы поддержки принятия решений по диагностике и лечению заболеваний и их практическое применение на примере ХБП 5Д / А. С. Галченков, В. О. Новицкий, Е. А. Кондратьев // Врач и информационные технологии. – 2020. – № 1. – С. 45-51. – DOI 10.37690/1811-0193-2020-1-45-51.

26. Монаков Д.М., Алтунин Д.В. Медицинские информационные системы: современные реалии и перспективы. Российский журнал телемедицины и электронного здравоохранения 2022;8(4):46-53; <https://doi.org/10.29188/2712-9217-2022-8-4-46-53>

27. Щамхалова К.К., Меринов Д.С., Артемов А.В., Гурбанов Ш.Ш. Искусственный интеллект и нейронные сети в урологии. Экспериментальная и клиническая урология 2023;16(2):32-37; <https://doi.org/10.29188/2222-8543-2023-16-2-32-37>.

28. Минаев П. В., Федяев Д. В., Серяпина Ю. В., Скоморохова Т. В. Обзор зарубежного опыта внедрения электронного здравоохранения // Фармакоэкономика. Современная фармакоэкономика и фармакоэпидемиология. 2021. №1. URL:

<https://cyberleninka.ru/article/n/obzor-zarubezhnogo-opyta-vnedreniya-elektronnogo-zdravooohraneniya> (дата обращения: 12.12.2024).

29. Руденко А.В. Руденко М.А. Каширина И.Л. Применение искусственных нейронных сетей для поиска объектов на медицинских изображениях. Моделирование, оптимизация и информационные технологии. 2024;12(3). Доступно по: <https://moitvivi.ru/ru/journal/pdf?id=1630> DOI: 10.26102/2310-6018/2024.46.3.013

30. Кузнецов П. П., Какорина Е. П., Алмазов А. А., Системы поддержки принятия врачебных решений на основе искусственного интеллекта — стратегия развития персонализированной медицины следующего этапа. Терапевт. 2020;1.

31. Анализ современных методов обработки изображений для устранения шумов и искажений на медицинских снимках / Д. А. Кобляков, А. Ю. Мягков, Е. А. Гусев, М. С. Юночкин // Информационные системы и технологии ист-2021 : сборник материалов XXVII Международной научно-технической конференции Нижегородский государственный технический университет им. Р.Е. Алексеева, Нижний Новгород, 23–24 апреля 2021 года / Нижегородский государственный технический университет им. Р.Е. Алексеева. – Нижний Новгород: Нижегородский государственный технический университет им. Р.Е. Алексеева, 2021. – С. 562-568.

32. Горелов, М. А. Применение капсульных нейронных сетей для анализа медицинских изображений / М. А. Горелов, Ю. В. Бруттан // Математическое моделирование систем и процессов : сборник материалов Международной научно-практической конференции, Псков, 10–11 ноября 2022 года. – Псков: Псковский государственный университет, 2022. – С. 13-18. – DOI 10.37490/978-5-00200-102-6-13-18.

33. Щукина, Н. А. Нейросетевые модели в задаче классификации медицинских изображений / Н. А. Щукина // Моделирование, оптимизация и информационные технологии. – 2021. – Т. 9, № 4(35). – DOI 10.26102/2310-6018/2021.35.4.022.

34. A comparative study of three deep learning-based methods for Segmentation of Lung lesions associated with COVID-19 in 3D CT images / V. A. Kovalev, V. A. Liauchuk, E. V. Snezhko, S. V. Trukhan // Big Data and Advanced Analytics. – 2021. – No. 7-1. – P. 13-19.

35. Абульханов С.Р., Слесарев О.В., Стрелков Ю.С., Байриков И.М. технология высокочувствительного анализа медицинских диагностических изображений // Современ. технол. мед.. 2021. №2. URL: <https://cyberleninka.ru/article/n/tehnologiya-vysokochuvstvitel'nogo-analiza-meditsinskih-diagnosticheskikh-izobrazheniy> (дата обращения: 22.08.2024).

36. Гермашев, И. В. Применение моделей нечеткой математики для решения задач медицинской диагностики / И. В. Гермашев, В. И. Дубовская // Математическая физика и компьютерное моделирование. – 2021. – Т. 24, № 4. – С. 53-66. – DOI 10.15688/mpcm.jvolsu.2021.4.4.

37. Панова, И. В. Применение нечеткой логики принятия решений в диагностике почечных патологий / И. В. Панова, С. Е. Токмакова // Научное сообщество студентов XXI столетия. Технические науки : Сборник статей по материалам CXXXV студенческой международной научно-практической конференции, Новосибирск, 04 марта 2024 года. – Новосибирск: ООО "Сибирская академическая книга", 2024. – С. 23-28.

38. Маннаа, А. С. Алгоритм обработки рентгеновских изображений с использованием нечеткой логики / А. С. Маннаа // Advanced Engineering Research (Rostov-on-Don). – 2024. – Т. 24, № 3. – С. 293-300. – DOI 10.23947/2687-1653-2024-24-3-293-300.

39. Гермашев, И. В., Дубовская, В. И. Применение моделей нечеткой математики для решения задач медицинской диагностики // Математическая физика и компьютерное моделирование. 2021. №4. URL: <https://cyberleninka.ru/article/n/primenenie-modeley-nechetkoy-matematiki-dlya-resheniya-zadach-meditsinskoy-diagnostiki> (дата обращения: 23.01.2025).

40. Коробова Л. А., Гладких Т. В. Разработка модели принятия решения для постановки диагноза заболеваний на основе нечеткой логики // Вестник ВГУИТ. 2018. №4 (78). URL: <https://cyberleninka.ru/article/n/razrabotka-modeli-prinyatiya-resheniya-dlya-postanovki-diagnoza-zabolevaniy-na-osnove-nechetkoy-logiki> (дата обращения: 23.01.2025).

41. Махаров, К. Построение базы нечётких правил в интеллектуальных системах для поддержки принятия решений / К. Махаров // Colloquium-journal. – 2023. – № 11 (170). – URL: <https://cyberleninka.ru/article/n/postroenie-bazy-nechyotkih-pravil-v-intellektualnyh-sistemah-dlya-podderzhki-prinyatiya-resheniy> (дата обращения: 28.01.2025).

42. Хамад Ю.А., Симонов К.В., Кенц А.С. алгоритмы сегментации и распознавания объектов на медицинских изображениях на основе шпиралет-преобразования и нейронных сетей // Информатизация и связь 2020. №2 С. 35-45. URL: <https://www.elibrary.ru/item.asp?id=42976411> (дата обращения: 16.01.2022).

43. Шагалова П.А., Ерофеева А.Д., Орлова М.М., Чистякова Ю.С., Соколова Э.С. Исследование алгоритмов предобработки изображений для повышения эффективности распознавания медицинских снимков // Труды НГТУ им. Р. Е. Алексеева 2020. №1(128) URL: <https://cyberleninka.ru/article/n/issledovanie-algoritmov-predobrabotki-izobrazheniy-dlya-povysheniya-effektivnosti-raspoznavaniya-meditsinskih-snimkov/viewer> (дата обращения: 14.02.2022).

44. Шубкин, Е. О. Обзор методов сегментации медицинских изображений / Е. О. Шубкин // Молодежь и современные информационные технологии : Сборник трудов XVIII Международной научно-практической конференции студентов, аспирантов и молодых ученых, Томск, 22–26 марта 2021 года. – Томск: Национальный исследовательский Томский политехнический университет, 2021. – С. 90-91.

45. Segmentation Based on Propagation of Dynamically Changing Superpixels / V. V. Danilov, O. M. Gerget, I. P. Skirnevskiy [et al.] // Programming and Computer Software. – 2020. – Vol. 46, No. 3. – P. 195-206. – DOI 10.1134/S0361768820030044.

46. Хамад, Ю. А. Алгоритмы сегментации и распознавания объектов на медицинских изображениях на основе шпиралет-преобразования и нейронных сетей / Ю. А. Хамад, К. В. Симонов, А. С. Кенц // Информатизация и связь. – 2020. – № 2. – С. 35-45. – DOI 10.34219/2078-8320-2020-11-2-35-45.

47. Годунов, А. И. Сегментация изображений и распознавание объектов на основе технологии сверточных нейронных сетей / А. И. Годунов, С. Т. Балаян, П. С.

Егоров // Надежность и качество сложных систем. – 2021. – № 3(35). – С. 62-73. – DOI 10.21685/2307-4205-2021-3-8.

48. Стернин В. Е., Дохов М. А., Тихомирова А. А., Дементьев Н. А. Современные подходы к классификации объектов на медицинских компьютерных изображениях // Визуализация в медицине . 2024. №2. URL: <https://cyberleninka.ru/article/n/sovremennye-podhody-k-klassifikatsii-obektov-na-meditsinskih-kompyuternyh-izobrazheniyah> (дата обращения: 23.01.2025).

49. Стернин В.Е., Дементьев Н.А. Проблемы, возникающие при классификации объектов на медицинских компьютерных изображениях. В кн.: актуальные проблемы биомедицины — 2024. Материалы XXX Всероссийской конференции молодых ученых с международным участием. Санкт-Петербург; 2024: 168-169.

50. Борисов Д.Н., Кульнев С. В., Лемешкин Р. Н. Использование искусственного интеллекта при анализе цифровых диагностических изображений// Состояние и перспективы развития современной науки по направлению «Техническое зрение и распознавание образов». 2019. С. 163-169 URL: <https://www.elibrary.ru/item.asp?id=41824272> (дата обращения: 28.02.2022).

51. Козарь Р.В., Навроцкий А.А., Гуринович А.Б. Методы распознавания медицинских изображений в задачах компьютерной диагностики// Известия Гомельского государственного университета имени Ф. Скорины 2020. №3 (120). URL: https://elib.gsu.by/bitstream/123456789/11756/1/Kozar_Recognition_methods_for_medical.pdf (дата обращения: 12.02.2022).

52. Савкин, А. Е. Исследование применения технологий компьютерного зрения для анализа биомедицинских изображений / А. Е. Савкин, П. А. Шагалова, О. Н. Корелин // Труды НГТУ им. Р.Е. Алексеева. – 2024. – № 1(144). – С. 16-23.

53. Бордаков, А. С. Алгоритмы детектирования объектов на основе нейронных сетей / А. С. Бордаков // Far East Math - 2021 : Материалы национальной научной конференции, Хабаровск, 01–30 ноября 2021 года / Редакционная коллегия: Е.Г. Агапова (ответственный редактор) [и др.]. – Хабаровск: Тихоокеанский государственный университет, 2021. – С. 28-33.

54. Бруттан, Ю. В. Исследование нейронных сетей для анализа медицинских изображений / Ю. В. Бруттан, А. Новиков // Вестник Псковского государственного университета. Серия: Технические науки. – 2020. – № 11. – С. 49-54.

55. Применение нейронных сетей для дифференциальной диагностики лёгочных патологий по рентгенологическим изображениям / С. М. Борзов, А. В. Карпов, О. И. Потатуркин, А. О. Хадзиев // Автометрия. – 2022. – Т. 58, № 3. – С. 61-71. – DOI 10.15372/AUT20220307.

56. Research on machine learning methods for recognition and classification of cardiovascular pathologies / S. B. Rakhmetulayeva, B. M. Ukibassov, Zh. O. Zhanabekov, A. K. Mukasheva // Вестник Алматинского университета энергетики и связи. – 2023. – No. 2(61). – P. 106-114. – DOI 10.51775/2790-0886_2023_61_2_106.

57. Скубрий, Д. В. Применение машинного обучения для анализа медицинских изображений / Д. В. Скубрий // Поколение будущего: Взгляд молодых ученых - 2024 : сборник научных статей 13-й Международной молодежной научной конференции, Курск, 12–13 ноября 2024 года. – Курск: ЗАО «Университетская книга», 2024. – С. 156-158.

58. Жилияков, А. А. Применение анализа текстур рентгенограмм для определения признаков остеоартрита плечевого сустава / А. А. Жилияков, Е. А. Волокитина // Вестник УГМУ. – 2024. – № 2. – С. 40-52.

59. Корепанов, В. Д. Автоматизация процесса анализа изображений компьютерной томографии / В. Д. Корепанов, В. П. Кулагин // Информатизация образования и науки. – 2022. – № 2(54). – С. 142-153.

60. Алгоритмы компьютерного зрения в задаче обработки серии медицинских снимков, полученных при микроскопии / П. А. Шагалова, Э. С. Соколова, Г. Я. Левин [и др.] // Cloud of Science. – 2020. – Т. 7, № 1. – С. 180-188.

61. Применение алгоритма компьютерного зрения для определения очагов демиелинизации при рассеянном склерозе на МРТ-изображениях / Б. Н. Тучинов, В. Суворов, К. О. Моторин [и др.] // Сибирский научный медицинский журнал. – 2024. – Т. 44, № 1. – С. 107-115. – DOI 10.18699/SSMJ20240111.

62. Руденко М. А., Крутиков Е. С., Бурдин Д. В. Система оценки адаптивных свойств организма по результатам капилляроскопии с использованием искусственных нейронных сетей. Доклад на II Всероссийская научно-техническая конференция «Состояние и перспективы развития современной науки по направлению «Техническое зрение и распознавание образов», Технополис Эра, г. Анапа, 18 марта 2021 г.

63. Руденко, М. А. Нечеткая модель классификации медицинских изображений на основе нейронных сетей / М. А. Руденко, А. В. Руденко // Международная конференция по мягким вычислениям и измерениям. – 2021. – Т. 1. – С. 336-339.

64. Boominathan L., Kruthiventi S.S., Babu R.V. CrowdNet: A Deep Convolutional Network for Dense Crowd Counting / L. Boominathan, S.S. Kruthiventi, R.V. Babu // Proceedings of the 2016 ACM on Multimedia Conference – 2016. – P. 640-644.

65. Illustrated: 10 CNN Architectures [Электронный ресурс] / URL: <https://towardsdatascience.com/illustrated-10-cnn-architectures-95d78ace614d#a253>.

66. Five Powerful CNN Architectures [Электронный ресурс] / URL: <https://medium.com/datadriveninvestor/five-powerful-cnn-architectures-b939c9ddd57b>.

67. Третье поколение нейросетей: «Глубокие нейросети» [Электронный ресурс] / URL: <https://www.mql5.com/ru/articles/1103>.

68. Common architectures in convolutional neural networks [Электронный ресурс] / URL: <https://www.jeremyjordan.me/convnet-architectures/>.

69. A Survey of the Recent Architectures of Deep Convolutional Neural Networks [Электронный ресурс] / URL: <https://arxiv.org/ftp/arxiv/papers/1901/1901.06032.pdf>.

70. Srivastava, S., Divekar, A.V., Anilkumar, C. et al. Comparative analysis of deep learning image detection algorithms. J Big Data 8, 66 (2021). <https://doi.org/10.1186/s40537-021-00434-w>.

71. Ding J. Convolutional neural network with data augmentation for sar target recognition/ Ding J, Chen B, Liu H, Huang M. // IEEE Geosci Rem Sens Lett. – 2016. – Vol. 13 – P. 364–368.

72. Zhou J. Using convolutional neural networks and transfer learning for bone age classification. / Zhou J, Li Z, Zhi W, Liang B, Moses D, Dawes L. // international conference on digital image computing: techniques and applications (DICTA). IEEE. – 2017. - P. 1–6.

73. Сирота, А. А., Митрофанова, Е. Ю., Милованова, А. И. (2019). Анализ алгоритмов поиска объектов на изображениях с использованием различных модификаций сверточных нейронных сетей. Вестник ВГУ. Серия: Системный анализ и информационные технологии, (3), 123-137. <https://doi.org/10.17308/sait.2019.3/1313>

74. YOLO: Real-Time Object Detection. — Текст : электронный // jreddie.com : [сайт]. — URL: <https://pjreddie.com/darknet/yolo/> (дата обращения: 18.03.2022).

75. Priya, Dwivedi YOLOv5 compared to Faster RCNN. Who wins? / Dwivedi Priya. — Текст : электронный // towardsdatascience.com : [сайт]. — URL: <https://towardsdatascience.com/yolov5-compared-to-faster-rcnn-who-wins-a771cd6c9fb4> (дата обращения: 28.04.2022).

76. YOLOv5: state-of-the-art модель для распознавания объектов. — Текст: электронный // neurohive.io: [сайт]. — URL: <https://neurohive.io/ru/papers/yolov5-state-of-the-art-model-dlya-raspoznvaniya-obektov/> (дата обращения: 28.04.2022).

77. Брехт Э. А., Коншина В. Н. Применение нейронной сети YOLO для распознавания дефектов // Интеллектуальные технологии на транспорте. 2022. №2 (30). URL: <https://cyberleninka.ru/article/n/primenenie-neyronnoy-seti-yolo-dlya-raspoznvaniya-defektov> (дата обращения: 11.12.2024).

78. Документация Ultralytics YOLOv8. [Электронный ресурс]: <https://docs.ultralytics.com/ru/>. (дата обращения: 01.09.2023).

79. YOLOv8-Based Automated Helmet Detection System for Enhanced Workplace Safety in Industrial Environments. [Электронный ресурс]. Режим доступа: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4727525 (дата обращения: 10.01.2024).

80. Comparison Study of Corn Leaf Disease Detection based on Deep Learning YOLO-v5 and YOLO-v8 / N. Chitrainingrum, L. Banowati, D. Herdiana [et al.] // Journal of

Engineering and Technological Sciences. – 2024. – Vol. 56, No. 1. – P. 61-70. – DOI 10.5614/j.eng.technol.sci.2024.56.1.5.

81. Использование нейронной сети YOLOv8 для детектирования на изображении лабораторного грызуна (крысы или мыши) в установке «Квадратное открытое поле» / И. Л. Гринин, С. В. Кравченко, А. В. Чумаков, А. С. Тарасов // NovaUm.Ru. – 2023. – № 43. – С. 24-30.

82. Хрящев, В. В. Исследование алгоритмов на базе нейросетевой архитектуры YOLO в задаче детектирования полипов на колоноскопических видеоданных / В. В. Хрящев, Н. В. Котов, А. Л. Приоров // Труды Международной конференции по компьютерной графике и зрению «Графикон». – 2023. – № 33. – С. 590-597. – DOI 10.20948/graphicon-2023-590-597.

83. Lemay, Andreanne. (2019). Kidney Recognition in CT Using YOLOv3. 10.48550/arXiv.1910.01268.

84. Eshmuradov D.E, Iskandarova Sayora, Tulaganova F. K. An analysis of the use of the yolo algorithm in the diagnosis of blood cell images // SAI. 2024. №Special Issue 17. URL: <https://cyberleninka.ru/article/n/an-analysis-of-the-use-of-the-yolo-algorithm-in-the-diagnosis-of-blood-cell-images> (дата обращения: 11.12.2024).

85. Anna V. Neupokoeva, Semen A. Naydenov, Elena V. Shevchenko Analysis of Medical Images Classification Methods: The Case of Neutrophil Nuclei // JBPE. 2023. №3. URL: <https://cyberleninka.ru/article/n/analysis-of-medical-images-classification-methods-the-case-of-neutrophil-nuclei> (дата обращения: 11.12.2024).

86. Хрящев В. В. Использование методов глубокого машинного обучения в задаче обнаружения купола слепой кишки на видеоданных колоноскопического исследования // Модели, системы, сети в экономике, технике, природе и обществе. 2023. №4 (48). URL: <https://cyberleninka.ru/article/n/ispolzovanie-metodov-glubokogo-mashinnogo-obucheniya-v-zadache-obnaruzheniya-kupola-slepoy-kishki-na-videodannyh> (дата обращения: 11.12.2024).

87. Кравченко С. В., Алексеев А. В., Орлова Ю. А., Гринин И. Л., Матюшечкин Д. С. Проблемы детектирования объекта на изображении в задачах глубокого обучения в области компьютерного зрения на основе свёрточных

нейронных сетей // Инновации и инвестиции. 2020. №6. URL: <https://cyberleninka.ru/article/n/problemy-detektirovaniya-obekta-na-izobrazhenii-v-zadachah-glubokogo-obucheniya-v-oblasti-kompyuternogo-zreniya-na-osnove-svyortochnyh> (дата обращения: 11.12.2024).

88. Сверточные нейронные сети в диагностике новообразований кожи / В. Г. Никитаев, А. Н. Проничев, О. Б. Тамразова [и др.] // Безопасность информационных технологий. – 2021. – Т. 28, № 4. – С. 118-126. – DOI 10.26583/bit.2021.4.09.

89. Evaluation metrics for object detection and segmentation [Электронный ресурс] // OpenGenus IQ. – Режим доступа: <https://iq.opengenus.org/evaluation-metrics-for-object-detection-and-segmentation/> (дата обращения: 29.01.2025). – Загл. с экрана.

90. Андриянов, Н.А. Обнаружение объектов на изображении: от критериев Байеса и Неймана–Пирсона к детекторам на базе нейронных сетей EfficientDet / Н.А. Андриянов, В.Е. Дементьев, А.Г. Ташлинский // Компьютерная оптика. – 2022 – Т. 46, № 1 – С. 139-159. –DOI: 10.18287/2412-6179-СО-922.

91. Свидетельство на программу для ЭВМ от 28.09.2022 г. №2022667880 «Программа автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для детектирования».

92. Everingham, M. The Pascal Visual Object Classes Challenge: A Retrospective / M. Everingham, S. M. A. Eslami, L. Van Gool [et al.] // International Journal of Computer Vision. – 2015. – №. 111(1). – стр. 98-136. – DOI 10.1007/s11263-014-0733-5.

93. Yadav, K. Image detection in noisy images / K. Yadav, D. Mohan, A. S. Parihar // Proceedings - 5th International Conference on Intelligent Computing and Control Systems, ICICCS 2021 : 5, Madurai, 06–08 мая 2021 года. – Madurai, 2021. – стр. 917-923. – DOI 10.1109/ICICCS51141.2021.9432243.

94. Руденко А. В. Метод оценки результатов детектирования и классификации объектов на медицинских изображениях / А. В. Руденко, М. А. Руденко, И. Л. Каширина // Вестник Воронежского государственного университета. Серия:

Системный анализ и информационные технологии. – 2024. – № 1. – С. 137-148. – DOI 10.17308/sait/1995-5499/2024/1/137-148.

95. Лапин, В. Г. Нечеткая модель классификации медицинских изображений на основе нейронных сетей / В. Г. Лапин, А. В. Руденко // Искусственный интеллект: технологии развития человека : Сборник трудов международной научно-практической конференции, Симферополь, 13–16 сентября 2023 года. – Симферополь: ООО «Издательство Типография «Ариал», 2024. – С. 44-56.

96. Чернега В. С., Тлуховская-Степаненко Н. П., Еременко С. Н., Еременко А. Н. Сетевая модель для оценки длительности медицинского технологического процесса лазерной контактной литотрипсии. Врач и информационные технологии. 2018;4;75:82.

97. Руденко А.В. Руденко М.А. Каширина И.Л. Алгоритмы 3D-реконструкции и расчета параметров объектов по результатам детектирования на медицинских изображениях. Моделирование, оптимизация и информационные технологии. 2024;12(2). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1594> DOI: 10.26102/2310-6018/2024.46.3.013 (2.3.8)

98. Руденко М.А. Система детектирования и анализа объектов на КТ-снимках в урологии / Руденко М.А., Руденко А.В., Крапивина М.А., Лисовский В.С. // III Международная конференция по нейронным сетям и нейротехнологиям (NeuroNT'2022): сб. докладов. СПб.: СПбГЭТУ «ЛЭТИ», 16 июня 2022. С. 47-50. - ISBN 978-5-7629-3043-7.

99. Руденко А.В. Проектирование системы поддержки принятия врачебных решений в хирургии и урологии с использованием технологий компьютерного зрения. Вестник Воронежского института высоких технологий. 2024;18(3). Доступно по: <https://vestnikvvt.ru/ru/journal/pdf?id=1337>

100. Чернега В. С., Тлуховская-Степаненко Н. П., Еременко С. Н., Еременко А. Н. Прогнозирование времени трансуретральной гольмиевой литотрипсии в лечении уrolитиаза. Врач и информационные технологии. 2020;2;72:80. DOI: 10.37690/1811-0193-2020-2-72-80.

101. Руденко, М. А. Система поддержки принятия врачебных решений на основе компьютерного зрения / М. А. Руденко, О. С. Цветкова, А. В. Руденко // Искусственный интеллект: технологии развития человека : Сборник трудов международной научно-практической конференции , Симферополь, 13–16 сентября 2023 года. – Симферополь: ООО «Издательство Типография «Ариал», 2024. – С. 64-78.

102. Руденко А. В. Поддержка принятия врачебных решений при планировании проведения процедуры лазерной литотрипсии/ А. В. Руденко, М. А. Руденко // Известия ЮФУ. Технические науки. –2024. –№ 2 (238). –С. 278-289. DOI10.18522/2311-3103-2024-2-278-289.

103. Демушкина К. М., Демушкин М. О., Кузьмин А. В. Обзор методов проектирования систем поддержки принятия врачебных решений // Модели, системы, сети в экономике, технике, природе и обществе. 2022. №2 (42). URL: <https://cyberleninka.ru/article/n/obzor-metodov-proektirovaniya-sistem-podderzhki-prinyatiya-vrachebnyh-resheniy> (дата обращения: 12.12.2024).

104. Макшанов, А. В. Системы поддержки принятия решений : учебное пособие для вузов / А. В. Макшанов, А. Е. Журавлев, Л. Н. Тындыкарь. — 2-е изд., стер. — Санкт-Петербург : Лань, 2021. — 108 с. — ISBN 978-5-8114-8489-8. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/176903> (дата обращения: 16.12.2024).

105. Реброва, О. Ю. Эффективность систем поддержки принятия врачебных решений: способы и результаты оценки / О. Ю. Реброва // Клиническая и экспериментальная тиреоидология. – 2019. – Т. 15, № 4. – С. 148-155. – DOI 10.14341/ket12377.

106. Михеев А. Е. Подход к внедрению систем поддержки принятия врачебных решений на принципах сервис ориентированной архитектуры с использованием сервисов цифровой медицинской экосистемы. Менеджер здравоохранения. 2024; S:101–118. DOI: 10.21045/1811-0185-2024-S-101-118

107. Khan, Hassan Ali et al. “Brain tumor classification in MRI image using convolutional neural network.” *Mathematical biosciences and engineering : MBE* 17 5 (2020): 6203-6216 .

108. Коробова, Л. А. Системный подход при решении прикладных медицинских диагностических задач / Л. А. Коробова, Т. А. О. Эйнуллаев, Р. В. Тэн // Моделирование систем и процессов. – 2024. – Т. 17, № 3. – С. 52-61. – DOI 10.12737/2219-0767-2024-50-59.

109. Автоматизированная система классификации снимков УЗИ поджелудочной железы на основе метода посегментного спектрального анализа / С. А. Филист, Д. С. Кондрашов, А. Ю. Сухомлинов [и др.] // Моделирование, оптимизация и информационные технологии. – 2023. – Т. 11, № 1(40). – С. 2-3. – DOI 10.26102/2310-6018/2023.40.1.021.

110. Создание интеллектуальной системы анализа изображений барабанной перепонки для дифференциальной диагностики заболеваний уха / Д. И. Калинин, А. А. Карякин, У. Р. Захарченко [и др.] // Бюллетень Северного государственного медицинского университета. – 2023. – № 2(50). – С. 35-40.

111. Свидетельство на программу для ЭВМ от 28.09.2022 г. №2022667880 «Программа автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для детектирования».


112. Кузнецов, А. В. Цифровая обработка изображений : Учебное пособие для студентов, изучающих компьютерную графику, цифровую обработку изображений, анализ медицинских изображений / А. В. Кузнецов, Э. Л. Шишкина. – Воронеж : Воронежский государственный университет, 2023. – 160 с. – ISBN 978-5-9273-3636-4. – EDN SNATTC.

113. Свидетельство на программу для ЭВМ от 10.11.2022 г. № 2022681242 «Программа анализа результатов детектирования, расчета параметров и 3D – визуализации объектов, обнаруженных в результате детектирования на медицинских изображениях, полученных после компьютерной томографии».

114. Свидетельство на программу для ЭВМ от 23.06.2021 г. №2021660226 «Программа анализа и оценки результатов капилляроскопии с помощью нейронных сетей».


Приложение А

Диаграмма прецедентов



Приложение Б

Диаграмма последовательности



Приложение В

Описание работы системы

Система поддержки принятия медицинских решений в области хирургии и урологии запускается на выполнение путем выбора командного файла «sud.bat», находящегося в основной папке системы «SUD». Командный файл вызывает интерпретатор Python, осуществляется вызов главного модуля системы «main.py». Далее главный модуль вызывает на выполнение модуль формирования графического интерфейса «kidney_GUI.py». Пользователю на экране монитора будет сформирован графический интерфейс.

Внешний вид интерфейса системы представлен на рисунке 1.




Рисунок 1 - Вид главного окна системы поддержки принятия медицинских решений в области хирургии и урологии

Интерфейс системы поддержки принятия врачебных решений представлена кнопками, которые вызывают на выполнение модули системы (рисунок 2).




Рисунок 2 - Кнопки вызова модулей системы

Кнопка «Чтение данных КТ» вызывает на выполнение модуль автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для дальнейшего детектирования. Пользователю предлагается указать каталог, где располагаются данные результатов КТ по конкретному пациенту в виде DICOM файлов. Производится проверка корректности выбора каталога пользователем, в случае неправильного выбора система выводит предупреждение и возвращается в главное меню. В случае корректного выбора каталога производится чтение служебной информации – данных о имеющихся сериях снимков КТ. Пользователь-врач должен выбрать серию. Далее система производит чтение данных КТ выбранной серии, создает в выходном каталоге, указанным пользователем, папку с именем вида «ID_FIO», где ID – код пациента, FIO – фамилия пациента, указанные в служебной информации DICOM файлов. В указанной папке создается папка с текущей датой, когда произведено чтение данных КТ и формирование изображений для последующего детектирования объектов (рисунки 3-6).




Рисунок 3 - Выбор папки с данными пациента и папки для сохранения изображений




Рисунок 4 - Выбор серии снимков КТ для чтения данных и формирования изображений, создание конечной папки для сохранения изображений




Рисунок 5 - Созданные и сохраненные изображения внутренних органов пациента в корональной проекции




Рисунок 6 - Служебная информация системы о сохраненных изображениях

На этом работа модуля автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для дальнейшего детектирования заканчивается. Пользователю предлагается на выбор продолжить работу – выполнить поиск объектов на изображениях или вернуться в главное меню.

Вызов на выполнение модуля детектирования объектов с помощью выбранной архитектуры нейросети на изображениях результатов компьютерной томографии осуществляется из главного меню путем нажатия кнопки «Просмотр и поиск камней в почках», либо нажатием кнопки «Просмотр и поиск камней в

почках» после вывода служебной информации о сохранённых изображениях на предыдущем шаге.

В первом случае пользователю необходимо выбрать папку с сохраненными изображениями, во втором случае система самостоятельно продолжит работу в папке, где произошло сохранение изображений.

После выбора каталога система осуществляет проверку корректности выбора пользователя, система проверяет выбранный каталог на наличие в папке изображений. При корректном выборе пользователю предлагается просмотреть сохраненные в папке изображения внутренних органов. После просмотра при нажатии кнопки «Поиск камней» система начинает процедуру детектирования объектов с помощью нейросети архитектуры YOLOv5. Система производит чтение изображений из каталога, детектирование на изображении объектов заданных классов («почка», «камень»). Создает в папке подпапку «detect», куда сохраняются изображения с выделенными найденными объектами и файлами со служебной информации о найденных объектах (координаты центра объекта, размеры по вертикали и горизонтали, уверенность) для каждого изображения (рисунки 7 - 10).




Рисунок 7 - Выбор пользователем каталога сохраненных ранее изображений внутренних органов пациента




Рисунок 8 - Выбор каталога и просмотр изображений перед детектированием объектов




Рисунок 9 – Индикатор выполнения процедуры детектирования изображений системой с помощью нейросети YOLOv5




Рисунок 10 - Папка с сохраненными изображениями с детектированными объектами

При завершении работы модуля детектирования пользователю предлагается просмотреть изображения с найденными объектами (рисунок 11) и информацией о найденных объектах: координаты центра объекта, размеры по вертикали и горизонтали, уверенность определения. Пользователь на данном этапе имеет возможность как просмотреть детектированные изображения, в случае необходимости врач может удалить изображения, на которых система определила объекты некорректно. Возможность удалять изображения оставлена в версии системы, в дальнейшем при хорошем уровне обученности нейросети по детектированию данная возможность будет убрана ввиду отсутствия необходимости.




Рисунок 11 - Просмотр изображений с детектированными объектами

Далее пользователь имеет возможность запустить на выполнение модуль анализа результатов детектирования и расчета параметров объектов путем нажатия кнопки «Параметры камней» либо завершить работу и выйти в главное меню.

Модуль анализа результатов детектирования и расчета параметров объектов пользователь имеет возможность вызвать как из главного меню нажатием кнопки «Просмотр детектированных изображений», так и из предыдущего шага детектирования нажатием кнопки «Параметры камней».

После выбора пользователем кнопки «Просмотр детектированных изображений» ему предлагается выбрать папку, где находятся уже детектированные изображения. Система проверяет корректность выбора пользователя путем проверки наличия в выбранной папке папки «detect» и файлов со служебной информацией о найденных объектах. В случае некорректного выбора система выдаст предупреждающее сообщение и перейдет в главное меню системы. В случае корректного выбора каталога с детектированными изображениями система предложит пользователю просмотр детектированных изображений, как на рисунке 11.

При нажатии пользователем кнопки «Параметры камней» начинается выполнение модуль расчета параметров объектов. Система анализирует файлы со служебной информацией о найденных объектах, осуществляет «сборку» объектов «камни», выполняет расчет параметров данных объектов: линейные размеры, масса камня, средняя плотность камня, максимальная плотность камня по НУ, минимальная и средняя плотность по НУ. При выполнении расчетов параметров по каждому объекту запускается на выполнение функции модуля по 3-D визуализации объектов, осуществляется воксельная 3-D реконструкция камня по плотности НУ, по физической плотности, формирование изображений реконструкций. По окончании расчетов параметров всех найденных объектов «камней» пользователю предлагается просмотр параметров каждого из найденных объектов отдельно на правой и левой почке. Если в какой-либо почке камни не обнаружены, то просмотр по данной почке будет недоступен (рисунок 12).




Рисунок 12 - Просмотр параметров объектов «камней»

По каждому из найденных объектов типа «камень» выводятся следующие данные: изображение внутренних органов, где был обнаружен данный объект, корональная проекция объекта в срезе с максимальной суммарной плотностью по HU с указанием размеров по высоте и ширине, рассчитанные параметры в текстовом виде, проекции воксельной 3-D реконструкции по плотности по HU и приведенной средней плотности.

Дополнительно в папке с именем «stones» происходит сохранение 3D изображений камней с указанием светимости по шкале Хаунсфилда и по рассчитанной плотности камней (рисунок 13).

Как видно из рисунка, системой были созданы и сохранены 3D модели всех шести найденных в почке камней.




Рисунок 13 – Папка с сохраненными изображениями камней

При нажатии на 2-хмерное изображение камня происходит вызов функции построения трех проекций камня в разных плоскостях и объемной воксельной реконструкции камня и вывод их в отдельное окно (рисунок 14). Выход из экранной формы осуществляется закрытием данного окна.




Рисунок 14 - Построение реконструкции камня в различных плоскостях и 3-Д воксельная реконструкция

При нажатии кнопки «3-D модель камня» происходит вызов функции построения 3-хмерной интерактивной реконструкции камня и вывод модели в отдельное окно интерактивной модуля по 3D – визуализации объектов после первичной обработки результатов компьютерной томографии. Пример 3D – визуализации интерактивной реконструкции камней приведен на рисунке 15.





Рисунок 15 – Интерактивная 3D – визуализации реконструкции камней

При нажатии кнопки «3-D модель почки» происходит вызов функции построения 3-хмерной интерактивной реконструкции почки и вывод модели в отдельное окно интерактивной 3D – визуализации объектов после первичной обработки результатов компьютерной томографии (рисунок 16).

При нажатии кнопки «Печать параметров камней» происходит вызов на исполнение модуля поддержки принятия решений на основе экспертной системы, где происходит формирование документа с описанием и параметрами найденных в почках конкрементов, а также с таблицей выбора режимов работы лазера при проведении процедуры лазерной литотрипсии.

Просмотр и печать данного документа осуществляется с использованием системных средств работы с PDF документами. Печать осуществляется нажатием на значок принтера вверху слева экрана (рисунок 17). Печать документа возможна

на подключенный к рабочему месту принтер, установленный и выбранный «по умолчанию».



Правая почка

Левая почка

Рисунок 16 - Интерактивная 3D – визуализация почек




Рисунок 17 – Печать документа с информацией о найденных в почках камнях

Выбор другого принтера для печати документа осуществляется как на рисунке 18, путем выбора принтера из списка вверху, после выбора принтера необходимо нажать кнопку «Print».






Рисунок 18 – Выбор принтера для печати документа

При нажатии кнопки «Время разрушения камня» происходит вызов модуля поддержки принятия решений на основе экспертной системы, где происходит расчет времени разрушения камня на основе данных массы текущего объекта камня, параметров частоты и энергии лазера, формирование рекомендаций по выбору режима работы лазера и подбору значений энергии и частоты лазера, а также формирование документа с рассчитанной таблицей и графической ее визуализацией (рисунок 19).



Частота, Гц	8.0	9.0	10.0	11.0	12.0	13.0	14.0	15.0
Энергия, Дж	8.0	9.0	10.0	11.0	12.0	13.0	14.0	15.0
0.6	0.51	0.46	0.41	0.37	0.34	0.32	0.29	0.27
0.7	0.44	0.39	0.35	0.32	0.29	0.27	0.25	0.23
0.8	0.38	0.34	0.31	0.28	0.26	0.24	0.22	0.2
0.9	0.34	0.3	0.27	0.25	0.23	0.21	0.2	0.18
1.0	0.31	0.27	0.25	0.22	0.2	0.19	0.18	0.16
1.1	0.28	0.25	0.22	0.2	0.19	0.17	0.16	0.15
1.2	0.26	0.23	0.21	0.19	0.17	0.16	0.15	0.14
1.3	0.24	0.21	0.19	0.17	0.16	0.15	0.14	0.13
1.4	0.22	0.2	0.18	0.16	0.15	0.14	0.13	0.12
1.5	0.2	0.18	0.16	0.15	0.14	0.13	0.12	0.11
1.6	0.19	0.17	0.15	0.14	0.13	0.12	0.11	0.1
1.7	0.18	0.16	0.14	0.13	0.12	0.11	0.1	0.1
1.8	0.17	0.15	0.14	0.12	0.11	0.11	0.1	0.09
1.9	0.16	0.14	0.13	0.12	0.11	0.1	0.09	0.09
2.0	0.15	0.14	0.12	0.11	0.1	0.09	0.09	0.08
2.1	0.15	0.13	0.12	0.11	0.1	0.09	0.08	0.08
2.2	0.14	0.12	0.11	0.1	0.09	0.09	0.08	0.07
2.3	0.13	0.12	0.11	0.1	0.09	0.08	0.08	0.07
2.4	0.13	0.11	0.1	0.09	0.09	0.08	0.07	0.07



Рекомендации по подбору режима работы лазера

Режим для дробления осколков камней	
Режим работы для камней с низкой плотностью	
Режим работы при неудобных подходах инструмента	
Оптимальный режим работы	
Режим работы в зоне высокой плотности камня	
Режим работы с высоким риском нанесения травмы	
Малоэффективный режим работы	
Малоэффективный режим работы - не рекомендовано к применению	

Рисунок 19 – Интерфейс модуля и результат расчета времени разрушения камня в PDF файле

Работа с модулем расчета параметров найденных объектов заканчивается при нажатии кнопки «Выход». Происходит выход в предыдущее окно просмотра детектированных изображений. При нажатии кнопки «Выход» или закрытии экранной формы происходит возврат в главное меню системы.

Вызов на выполнение модуля настройки параметров системы осуществляется из главного меню системы поддержки принятия медицинских решений в области хирургии и урологии нажатием кнопки «НАСТРОЙКИ». Далее система выводит диалоговое окно (рисунок 20), где пользователю предлагается выбрать папку, откуда будет происходить чтение первичных данных результатов КТ, папку, куда по умолчанию будут сохраняться подготовленные модулем автоматизации процесса первичной обработки результатов компьютерной томографии и создания набора изображений для дальнейшего детектирования созданные изображения, где будут сохранены детектированные изображения с выделенными найденными объектами и служебной информацией о параметрах найденных объектов. Также здесь необходимо выбрать файл с весами обученной модели нейросети архитектуры YOLOv5, необходимый для детектирования объектов, цветовую схему, язык интерфейса системы, задать количество файлов изображений, получаемых из результатов КТ пациента, выбрать формат файла изображений. После нажатия на кнопку «Сохранить и выйти» введенные параметры сохраняются в файл настроек в соответствующей папке «config», система принимает новые настройки и перезапускается уже с новыми параметрами. Работа данного модуля завершается.




Рисунок 20 - Диалоговое окно настроек параметров системы поддержки принятия медицинских решений в области хирургии и урологии

Система имеет возможность сформировать набор размеченных изображений для последующего обучения нейросети. Для формирования набора изображений для обучения необходимо выполнить следующую последовательность действий.

Сначала необходимо в главном меню (рисунок 2) нажать кнопку «Формирование обучающего датасета». Затем выбрать каталог с изображениями, которые были получены из DICOM данных пациента, как на рисунке 7. Система покажет сформированные изображения, как на рисунке 8.

Далее в предложенном интерфейсе необходимо снять «флажок» с параметра «Сохранять уверенность поиска в файлах с метками», как на рисунке 21.




Рисунок 21 – Снятие «флажка» с параметра «Сохранять уверенность поиска в файлах с метками»

После этого необходимо нажать кнопку «Поиск камней» в данном окне. Система далее произведет поиск объектов на изображениях в выбранной папке с изображениями внутренних органов пациента (как на рисунке 9).

После окончания процедуры детектирования система покажет диалоговое окно просмотра детектированных изображений. Однако теперь в файле с метками будет отсутствовать показатель «уверенность» детектирования объектов (рисунок 22).




Рисунок 22 – Результаты детектирования объектов

После этого необходимо нажать кнопку «Выход» в данном окне.

Следующим шагом для формирования набора изображений для дальнейшего обучения нейросети необходимо нажать кнопку «Формирование обучающего датасета» в главном окне системы (рисунок 2). Система предложит выбрать папку с изображениями. Необходимо обязательно выбрать папку, куда были сохранены изображения на предыдущем шаге, и нажать кнопку «Выбор папки». Далее система

предложит выбрать папку для сохранения набора изображений для последующего формирования датасета для обучения нейросети (рисунок 23).




Рисунок 23 – Выбор папки для датасета

Система покажет диалоговое окно, где можно просмотреть размеченные изображения (рисунок 24). С помощью данного интерфейса можно осуществить добавление объекта на изображение и в файл с метками объектов. Для этого сначала необходимо справа выбрать класс объекта для его добавления (рисунок 25).




Рисунок 24 – Вид интерфейса выбора изображений для разметки датасета для обучения




Рисунок 25 – Выбор объекта для нанесения разметки на изображение

Далее необходимо нажать кнопку «Добавить объект». После нажатия появится окно, на котором можно с помощью «мышки» нанести ограничивающий прямоугольник (рисунок 26 и 27).




Рисунок 26 - Окно для рисования ограничивающего прямоугольника




Рисунок 27 - Нарисованный ограничивающий прямоугольник

После окончания рисования необходимо нажать на клавиатуре клавишу «пробел» или «enter». Система внесет сделанные изменения в файл с метками

объектов и файл с изображением. В результате на изображении появится ограничивающая объект рамка, которая была нарисована пользователем (рисунок 28).




Рисунок 28 – Внесение изменений на изображение

После этого нужно закрыть окно, в котором производилось выделение ограничивающей рамки для добавляемого объекта. Система обновит содержимой файла с метками объектов, размеченных на данном изображении (рисунок 29).




Рисунок 29 – Обновленный интерфейс с измененным содержимым файла меток

В случае необходимости удалить данные о разметке какого-либо объекта из файла с метками, необходимо сначала выбрать класс объекта из списка справа,

затем нажать кнопку «Удалить объект». Система произведет анализ содержимого файла с метками, и удалит строку, в которой содержатся данные удаляемого объекта. После этого будет обновлено содержимое файла с метками для данного изображения (рисунок 30).

После завершения добавления или удаления объектов на конкретном изображении, подобную операцию возможно повторить на всем наборе изображений. Также возможно удаление изображения, которое может не подходить для занесения его в датасет. Для этого необходимо нажать кнопку «Удалить» и текущее изображение вместе с текстовым файлом, содержащим данные о разметке, будут удалены.




Рисунок 30 – Выбор объекта для удаления данных о его разметке из текстового файла с метками, обновление содержимого на экране

В системе имеется возможность переносить одно текущее изображение в конечный датасет, либо, после просмотра всех изображений и добавления объектов на изображения, либо удаления объектов из разметки, возможно скопировать весь

набор изображений из данной папки в папку с набором изображений для обучающего датасета. Для этого необходимо включить «флажок» с параметром «Выбрать все изображения в датасет» и нажать кнопку «Сохранить изображения в датасет» (рисунок 31). С помощью кнопки «Удалить» имеется возможность удалить текущее изображение из будущего датасета для обучения.




Рисунок 31 – Копирование всех размеченных изображений в датасет

Система произведет копирование изображений в выбранную папку для набора изображений (датасета) и в папку с текстовыми файлами, содержащими информацию об размеченных объектах для последующего обучения нейросети (рисунок 32).




Рисунок 32 – Сохраненный набор изображений и текстовых меток для обучения нейросети

В папке «images» сохранены файлы с изображениями в форматах «png» и «jpg» (рисунок 33), в папке «labels» - файлы с параметрами размеченных объектов - метками объектов для каждого изображения.




Рисунок 33 – Изображения и текстовые файлы с метками в папке датасета для обучения нейросети

Приложение Г

Свидетельства о регистрации программ для ЭВМ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2022667880

Программа автоматизации процесса первичной
обработки результатов компьютерной томографии и
создания набора изображений для детектирования.

Правообладатель: **ОБЩЕСТВО ОГРАНИЧЕННОЙ
ОТВЕТСТВЕННОСТЬЮ «СМАРДИС» (RU)**

Автор(ы): **Руденко Андрей Владимирович (RU)**



Заявка № 2022667409

Дата поступления 28 сентября 2022 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 28 сентября 2022 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Документ подписан электронной подписью
Сертификат 68b80077e14e4010a94edbd24145d5c7
Владелец **Зубов Юрий Сергеевич**
Действителен с 20.03.2022 по 26.05.2023

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2022681242

Программа анализа результатов детектирования,
расчета параметров и 3D-визуализации объектов,
обнаруженных в результате детектирования на
медицинских изображениях, полученных после
компьютерной томографии

Правообладатель: **ОБЩЕСТВО С ОГРАНИЧЕННОЙ
ОТВЕТСТВЕННОСТЬЮ «СМАРДИС» (RU)**

Авторы: **Руденко Андрей Владимирович (RU), Руденко Марина
Анатольевна (RU), Лисовский Владимир Сергеевич (RU),
Крапивина Милада Андреевна (RU)**



Заявка № 2022680848

Дата поступления 03 ноября 2022 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 10 ноября 2022 г.

Руководитель Федеральной службы
по интеллектуальной собственности

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 68b80077e14c40f0a94e8bd24145d5c7
Владелец **Зубов Юрий Сергеевич**
Действителен с 2.01.2022 по 26.05.2023

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2021660226

**Программа анализа и оценки результатов
капилляроскопии с помощью нейронных сетей**

Правообладатель: *Федеральное государственное автономное
образовательное учреждение высшего образования
«Крымский федеральный университет имени В.И.
Вернадского» (RU)*

Авторы: *Руденко Марина Анатольевна (RU), Руденко Андрей
Владимирович (RU)*

Заявка № 2021619298

Дата поступления 15 июня 2021 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 23 июня 2021 г.



Руководитель Федеральной службы
по интеллектуальной собственности

Г.П. Ивлиев

Приложение Д

Протокол тестирования

«УТВЕРЖДАЮ»

Генеральный директор

ООО «СМАРДИС»

Руденко А.В.

2022 г.



ПРОТОКОЛ

тестовых испытаний

«Прототипа системы поддержки принятия медицинских решений в области хирургии и урологии»

г. Симферополь

«27» декабря 2022 г.

Настоящий протокол составлен по результатам тестирования на базе программно-технических средств Клинического медицинского многопрофильного центра Святителя Луки Крымского федерального университета им. В.И. Вернадского, проведенного рабочей группой КММЦ Святителя Луки в период с «01» ноября 2022 г. по «10» ноября 2022 г.

Условия, в которых проводилось тестирование.

Характеристики ПК: Процессор – Intel Core i5, оперативная память – 16 ГБ, HDD 1 ТБ, видеокарта Intel UHD Graphics интегрированная, монитор AOC 24", разрешение экрана - разрешение 2560*1440, операционная система – Windows 10, интерпретатор Python 3.9.

Тестирование проводилось по следующим режимам:

1. Первичная обработка данных компьютерной томографии (чтение служебной информации о сериях и изображениях КТ, анатомически верное создание изображений внутренних органов в корональной проекции нужного размера, сохранение набора изображений в выбранную папку на диске).
2. Детектирование объектов заданных классов на изображениях, полученных из результатов КТ пациентов (анатомически верное определение правой и левой почки, определение конкрементов в пределах почек).
3. Обработка результатов детектирования (графическая визуализация каждого из найденных конкрементов в плоскости с указанием линейных размеров, графическая 3D визуализация конкрементов по плотности HU и физической плотности, выполнение расчетов размеров конкрементов, плотности конкрементов, времени разрушения).

По результатам проведения тестирования установлено:

1. Работа прототипа системы поддержки принятия медицинских решений в области хирургии и урологии по первичной обработке данных компьютерной томографии признана удовлетворительной. Служебная информация результатов КТ читается корректно, изображения внутренних органов пациента создаются в корональной проекции анатомически верно, размер изображений соответствуют заявленным, границы органов, костей имеют четкие очертания, пригодные для просмотра, изображения имеют в нужной степени яркость и контрастность.
2. Работа прототипа системы поддержки принятия медицинских решений в области хирургии и урологии по детектированию объектов заданных классов на изображениях, полученных из результатов КТ пациентов признана удовлетворительной. Определение категорий объектов правой и левой почек производится в анатомически верном местоположении. Определение объектов категорий камней производится в пределах объектов почек.

3. Работа прототипа системы поддержки принятия медицинских решений в области хирургии и урологии по обработке результатов детектирования признана удовлетворительной. Визуализация конкрементов в плоскости и объемной реконструкции выполняются системой корректно, пропорции камней сохраняются. Расчет линейных размеров конкрементов, их массы, плотностей по Хаунсфилду и физической плотности выполняются верно. Расчет времени разрушения камня выполняется соответственно формуле, результаты расчетов являются верными, графическое представление результатов наглядным.

Выводы по результатам тестирования:

Работа прототипа системы поддержки принятия медицинских решений в области хирургии и урологии в целом признается удовлетворительной.

Прототип системы поддержки принятия медицинских решений в области хирургии и урологии может быть рекомендован для использования на автоматизированном рабочем месте хирурга-уролога.

Главный врач КММЦ Святителя Луки



С.Н. Еременко

Приложение Е

Акты внедрения



**«СТАВРОПОЛЬСКИЙ КРАЕВОЙ
КЛИНИЧЕСКИЙ КОНСУЛЬТАТИВНО-
ДИАГНОСТИЧЕСКИЙ ЦЕНТР»**

АВТОНОМНАЯ НЕКОММЕРЧЕСКАЯ
МЕДИЦИНСКАЯ ОРГАНИЗАЦИЯ

355017, г. Ставрополь, ул. Ленина, 304
Тел.: (8652)94-52-25, факс (8652)35-61-49

E-mail: skkdc@skkdc.ru

24.03.25 № 01-01/232

На № _____

АКТ

о внедрении результатов диссертационного исследования «Алгоритмы обработки и анализа изображений для интеллектуальной системы поддержки принятия решений в урологии»

Руденко Андрея Владимировича

Комиссия в составе: председателя комиссии – начальник отдела автоматизированных систем управления (АСУ) СКККДЦ, кандидат физико-математических наук Лапин Виталий Геннадьевич, членов комиссии: заместитель начальника отдела автоматизированных систем управления СКККДЦ, кандидат физико-математических наук Чулков Андрей Сергеевич, инженер-программист отдела автоматизированных систем управления СКККДЦ Павлов Андрей Сергеевич, составила настоящий Акт о том, что результаты диссертационного исследования Руденко А.В. по теме «Алгоритмы обработки и анализа изображений для интеллектуальной системы поддержки принятия решений в урологии» внедрены и используются в деятельности Автономной некоммерческой медицинской организации «Ставропольский краевой клинический консультативно-диагностический центр».

В частности, программный комплекс «Система поддержки принятия врачебных решений «SUD» применяется как инструмент предварительной диагностики патологий мочекаменной болезни по результатам компьютерной томографии внутренних органов.

Председатель комиссии:

Начальник отдела АСУ

В.Г. Лапин В.Г. Лапин

Члены комиссии:

Заместитель начальника отдела АСУ

А.С. Чулков А.С. Чулков

Инженер-программист отдела АСУ

А.С. Павлов А.С. Павлов

Ставрополь
24.03.2025

УТВЕРЖДАЮ

Проректор по научной деятельности

ФГАОУ ВО «Крымский федеральный
университет имени В.И. Вернадского»

Любомирский Н.В.



04 2025 г.

АКТ

о внедрении результатов диссертационной работы

Руденко Андрея Владимировича

Комиссия в составе: Председателя комиссии – Директора Физико-технического института КФУ имени В.И. Вернадского Нудьги А.А., членов комиссии: заведующий кафедрой компьютерной инженерии и моделирования к.т.н. Милюков В.В., доцент кафедры компьютерной инженерии и моделирования Сосновский Ю.В. составила настоящий Акт о том, что результаты диссертационного исследования Руденко А.В. по теме «Алгоритмы обработки и анализа изображений для интеллектуальной системы поддержки принятия решений в урологии» внедрены в учебный процесс ФГАОУ ВО «Крымский федеральный университет имени В.И. Вернадского»:

- по направлениям 09.03.01 «Информатика и вычислительная техника» и 09.03.04 «Программная инженерия» в программах дисциплин «Системы искусственного интеллекта», «Интеллектуальный анализ данных»;

- по направлению 09.04.01 «Информатика и вычислительная техника» в программе дисциплины «Интеллектуальные системы и программные комплексы»;

- по направлению 10.05.01 «Компьютерная безопасность» в программе дисциплины «Нейронные сети».

Председатель комиссии

Члены комиссии

Нудьга А.А.

Милюков В.В.

Сосновский Ю.В.

УТВЕРЖДАЮ

Проректор по цифровой трансформации
 ФГАОУ ВО «Крымский федеральный
 университет имени В.И. Вернадского»

Рыбась А.Ф.

2025 г.



АКТ

о внедрении результатов диссертационной работы

Руденко Андрея Владимировича

Комиссия в составе: Председателя комиссии – директора Ордена Трудового Красного Знамени Медицинского института им. С.И. Георгиевского (структурное подразделение) «КФУ имени В.И. Вернадского», доктора медицинских наук, профессора Крутикова Е.С., членов комиссии: заместителя декана по научно-исследовательской работе, к.м.н. Балакчиной А. И., директора Центра ИИ и АБД «КФУ имени В.И. Вернадского», к.т.н. Руденко М.А. составила настоящий Акт о том, что результаты диссертационного исследования Руденко А.В. по теме «Алгоритмы обработки и анализа изображений для интеллектуальной системы поддержки принятия решений в урологии» в форме СППВР внедрены и используются в деятельности Ордена Трудового Красного Знамени Медицинского института им. С.И. Георгиевского (структурное подразделение) «КФУ имени В.И. Вернадского» для подготовки специалистов на клинических кафедрах, в том числе в поликлинике Многопрофильной Клинической Больницы Святителя Луки «КФУ имени В.И. Вернадского».

Председатель комиссии

Члены комиссии

Е.С. Крутиков

А.И. Балакчина

М.А. Руденко